



THÈSE

En vue de l'obtention du

DOCTORAT DE L'UNIVERSITÉ DE TOULOUSE

Délivré par : *l'Université Toulouse 3 Paul Sabatier (UT3 Paul Sabatier)*

Présentée et soutenue le 25/1/2016 par :

PIERRE DUBOSCLARD

**Segmentation automatique d'images sur des critères géométriques,
application à l'inspection visuelle de produits agroalimentaires.**

JURY

FRÉDÉRIC LERASLE
MICHEL DEVY
ARIANE HERBULOT
XAVIER DESCOMBES
THIERRY FOURNEL
DAVID FOFI
HUBERT KONIK
STANISLAS LARNIER

Pr. Univ. UPS
DR CNRS
MCF UPS
DR INRIA
Pr. Univ. UJM
Pr. IUT Le Creusot
MCF UJM
LAAS CNRS

Président du jury
Directeur de thèse
Directeur de thèse
Rapporteur
Rapporteur
Examineur
Membre du jury
Membre du jury

École doctorale et spécialité :

EDSYS : Informatique 4200018

Unité de Recherche :

LAAS - Laboratoire d'Analyse et d'Architecture des Systèmes (UPR 8001)

Directeur(s) de Thèse :

Michel DEVY et Ariane HERBULOT

Rapporteurs :

Xavier DESCOMBES et Thierry FOURNEL

Remerciements

Je tiens en premier lieu à remercier Mr Jean-Christophe Mifsud, créateur et PDG de l'entreprise Alpha MOS, pour m'avoir offert la chance de mener ces travaux de thèse, ainsi que Mr Alain Gaudon, instigateur de ce projet, sans qui je n'aurais sans doute jamais parcouru tout ce chemin... merci à toi !

Je remercie Michel, Ariane et Hubert, pour avoir accepté d'encadrer mes travaux. J'ai beaucoup appris à vos côtés durant ces quelques années partagées, sur des aspects techniques, mais aussi humains. Je ne peux manquer d'y adjoindre Stanislas, avec qui cela a été un réel plaisir de travailler, cette collaboration s'étant avérée productive et extrêmement enrichissante !

Je tiens également à remercier mes encadrants au sein de l'entreprise Alpha MOS, Mr Olivier Cabrol, Mr Hervé Lechat et Me Geneviève Carayon, pour leur disponibilité et pour le cadre qu'ils ont su aménager malgré un contexte pas toujours facile.

Je remercie également divers acteurs croisés à différentes périodes de ma thèse, à différents endroits : Mr Philippe Colantoni et Mr Olivier Alata de l'université Jean Monnet de Saint-Etienne ; Mr Yannck Deville de l'université Paul Sabatier à Toulouse ; Mr Patrick Danes du LAAS CNRS et Me Hélène Thirion de l'école doctorale Système de Toulouse.

Je remercie également mes co-bureaux et autres doctorants de l'équipe, pour les moments passés ensemble et les échanges, productifs ou non, mais nécessaires et indispensables : Ali, Christophe, Fix, Laurent, Alexandre, merci à vous...

Enfin, ces travaux sont dédiés à ma famille et à Caroline, qui m'accompagne au quotidien ; autant d'acteurs sans qui rien n'aurait été possible, merci pour votre soutien indéfectible...

Table des matières

1	Introduction	7
1.1	Introduction générale	7
1.2	Contexte industriel	8
1.3	Contexte applicatif	9
1.4	Problématiques	11
1.5	Contraintes industrielles	12
1.6	Organisation	13
2	Acquisition	15
2.1	Système d'acquisition	15
2.1.1	Marché	16
2.1.2	Enceinte	18
2.1.3	Éclairage	19
2.1.4	Dispositif d'acquisition	21
2.2	Caractéristiques du système d'acquisition	21
2.2.1	Distorsion	21
2.2.2	Géométrie et homogénéité d'éclairage	22
2.2.3	Stabilité de l'éclairage	24
2.2.4	Homogénéité spatiale	25
2.3	Optimisation des acquisitions	26
2.3.1	Débruitage	27
2.3.2	Étalonnage colorimétrique	28
2.3.3	Mesures	31
3	Apprentissage de modèles de forme	37
3.1	Séparation objets-fond	38
3.2	Attributs/Paramètres	39
3.2.1	Attributs géométriques	39
3.2.2	Moments de Hu	41
3.2.3	Descripteurs de Fourier	43
3.2.4	Transformée en distance	45
3.3	Protocoles envisagés	47
3.3.1	Forme moyenne	48

3.3.2	Modélisation d'une forme moyenne	50
3.4	Résultats d'apprentissage de modèles de forme	54
4	Détection	61
4.1	État de l'art	61
4.2	Outils	63
4.2.1	Séparation objets/fonds	64
4.2.2	Indicateurs	64
4.2.3	Assemblage des indicateurs	69
4.2.4	Tenseur de structure	71
4.2.5	Contour actif	77
4.2.6	Validation d'un objet détecté	81
4.3	Méthodes de détection	82
4.3.1	Approche probabiliste	82
4.3.2	Approche déterministe	86
4.4	Techniques d'évaluation de la détection	88
4.5	Résultats de la détection	90
5	Exploitations et perspectives	97
5.1	Exploitations	97
5.1.1	Riz	97
5.1.2	Pois	98
5.1.3	Indice de confiance	98
5.2	Perspectives	99
5.2.1	Acquisitions proche infrarouge et ultraviolet	99
5.2.2	Résultats	101
6	Conclusion	105
6.1	Conclusion générale	105
6.2	Axes d'amélioration	106
6.3	Publications	108
A	Annexes	111
A.1	Rapport d'évaluation de la bibliothèque mise à disposition de l'entreprise	111

Chapitre 1

Introduction

1.1 Introduction générale

La récolte mondiale de céréales atteint plusieurs milliards de tonnes chaque année. Les variétés sont diverses et nombreuses (blé, riz, orge, maïs, avoine, mil, quinoa, ...) et leurs cultures varient selon les pays, en fonction des climats et de la nature des sols, mais également de critères culturels. Ainsi, historiquement et traditionnellement, les civilisations européennes ont cultivé majoritairement le blé, les asiatiques le riz, les amérindiennes le maïs et les africaines le mil. La culture de ces plantes destinées à l'alimentation humaine ou animale marque un tournant dans l'histoire de l'agriculture : les grains de céréales récoltés fournissent en effet une alimentation riche en termes d'apport calorique, les rendements des cultures sont élevés et la bonne conservation des grains permet la création de réserves. D'un point de vue botanique, les céréales telles que nous les connaissons aujourd'hui ont été obtenues par sélections et croisements depuis des espèces de céréales sauvages.

Les céréales sont devenues au fil des époques un des éléments de base de l'alimentation : au début du 21^e siècle, elles représentaient à hauteur de 45% des calories alimentaires de l'humanité. Elles sont consommées sous forme brute (en grains) ou transformée (farines, flocons, semoules, pâtes). L'homme est le principal consommateur de céréales, bien que 37% de la production mondiale soient destinés à l'alimentation d'animaux d'élevages.

La culture et l'échange des céréales représentent donc un enjeu majeur en ce qui concerne l'alimentation à l'échelle mondiale. Les échanges et transactions de céréales sont régis par les cours fixés par le marché, mais également par la qualité intrinsèque des produits. Dans ce contexte de marché toujours plus concurrentiel, en particulier sur les biens de consommation, la différenciation par rapport à la concurrence est un enjeu de taille, contribuant fortement au succès d'un produit. Parmi les critères de qualité, l'aspect visuel est primordial car il constitue en général la première perception qu'a le consommateur du produit. Aussi les industriels sont amenés à particulièrement soigner

l'apparence de leurs produits et ont pour cela recours à l'analyse visuelle. En matière d'analyse visuelle, on distingue :

- l'analyse en ligne, essentiellement destinée à contrôler la qualité de tous les produits et détecter les défauts sur les chaînes à haute cadence de production. Souvent, le contrôle porte sur des paramètres d'un seul et même type : les dimensions, la forme ou la couleur [27] ;
- l'analyse hors ligne, qui est généralement employée sur un échantillon prélevé de manière aléatoire dans la production, lorsque la rapidité et la fréquence des contrôles sont moins critiques.

Sur le segment de l'analyse visuelle hors ligne existent déjà plusieurs techniques :

- l'analyse humaine, réalisée par un panel de juges (aussi appelé panel sensoriel), peut être menée dans les conditions ambiantes ou, pour plus de reproductibilité, dans une cabine à lumière permettant d'observer le produit dans un environnement dont les conditions d'éclairage sont contrôlées. Les juges évaluent des paramètres précis du produit ou notent le produit dans sa globalité. Il peut s'agir de tests analytiques objectifs (discriminatifs ou descriptifs) ou de tests consommateurs subjectifs ;
- l'analyse instrumentale via un colorimètre ou un spectrophotomètre, consiste à mesurer uniquement les paramètres de couleur, soit d'une portion du produit, soit la couleur moyenne du produit pris dans sa globalité ;
- l'analyse instrumentale à l'aide d'une cabine de mesure éclairée dans laquelle est capturée une image des produits, image qui sert de base à des traitements de données relativement peu avancés (analyse globale sur la couleur moyenne de l'échantillon, pas de segmentations des objets).

1.2 Contexte industriel

Les travaux menés dans le cadre de cette thèse sous convention CIFRE ont été réalisés pour le compte de l'entreprise Alpha MOS [39]. Cette entreprise a été créée en 1993 par Monsieur Jean Christophe MIFSUD, actuel PDG de la société. Alpha MOS est cotée en bourse depuis 1998 sur le marché Euronext Paris Compartiment C. Le siège social d'Alpha MOS est basé à Toulouse, le groupe intègre par ailleurs trois filiales basées à Baltimore (États-Unis), Tokyo (Japon) et Shanghai (Chine). Les équipes de Recherche et Développement d'Alpha MOS comprennent une dizaine de Docteurs, maîtrisant un ensemble de domaines de l'analyse chimique et sensorielle aux mathématiques statistiques.

L'activité principale d'Alpha MOS est la conception et la commercialisation d'instruments d'analyse et de corrélation sensorielle (odorat, goût et vision) tels que le nez et la langue électronique et plus récemment l'œil électronique. Ces instruments ont pour vocation d'évaluer de façon fiable et reproductible la qualité organoleptique et visuelle

de produits principalement agroalimentaires.



(a)

FIGURE 1.1 – Système d’analyse visuelle.

Dans ce contexte Alpha MOS a développé en 2011 un nouveau système d’analyse visuelle, nommé IRIS VA 300 (figure 1.1), basé sur une méthodologie simple d’acquisition et d’analyse d’images. Ce système répondait à des besoins exprimés par l’industrie agroalimentaire mais se trouvait limité dans son approche et sa capacité à détecter les objets, notamment quand ceux-ci étaient collés. Alpha MOS a donc choisi de s’engager dans un programme de recherche dans le but de mettre au point de nouveaux outils permettant notamment de détecter des objets au sein d’images complexes de produits agroalimentaires, d’identifier et de caractériser ces formes. La complexité des images provient du nombre important d’objets qu’elle comporte, ainsi que de leur disposition non ordonnée. Des exemples d’images sont présentés en figure 1.2. En raison d’un besoin clairement identifié sur le marché des céréales et de l’absence de solution industrielle pour y répondre, l’entreprise a choisi d’axer les travaux menés dans le cadre de cette thèse sur une application dont les besoins avaient été clairement exprimés : l’inspection visuelle de grains de céréales.

1.3 Contexte applicatif

L’inspection visuelle de grains de céréales représente une étape majeure et incontournable de toute transaction dans le milieu céréalier. Les volumes étant trop importants pour être contrôlés dans leur totalité, des méthodes d’échantillonnage ont été mises au point et sont utilisées lors des transactions. Pour chaque lot, un échantillon jugé représentatif est prélevé et inspecté. Pour que les données qui en sont extraites soient significatives, l’échantillon doit être rigoureusement caractérisé. Cette inspection visuelle




FIGURE 1.2 – Deux exemples d’images complexes de grains d’orge (1.2a) et de riz (1.2b).

est historiquement réalisée par un opérateur qui inspecte l’échantillon grain par grain. Ce travail, particulièrement difficile et délicat, peut également être source de conflit entre vendeurs et acheteurs, chacun pouvant remettre en cause les résultats fournis par l’opérateur. Ce procédé est en effet exposé à différents problèmes :

- les résultats obtenus par un opérateur ne sont pas parfaitement répétables : son état de fatigue visuelle peut par exemple influencer son appréciation et donc les résultats ;
- l’évaluation dépend directement de l’opérateur : elle n’est pas reproductible, les résultats peuvent varier d’un opérateur à l’autre.

C’est dans ce contexte que nous nous proposons de mettre au point un système permettant de traiter l’inspection visuelle de grains de céréales de manière automatique.

L’entreprise Alpha MOS développe des systèmes pour le contrôle de qualité de produits alimentaires. Elle propose en particulier un système d’inspection visuelle (figure 1.1). Nous nous proposons d’adapter et d’améliorer ce système pour mettre au point un système d’inspection visuelle, capable de réaliser cette évaluation sur un échantillon de grains de céréales, de manière répétable et reproductible, qui apporterait une alternative à l’évaluation humaine et qui permettrait d’annihiler les divergences entre le vendeur et l’acheteur. L’évaluation doit être simple à mettre en œuvre et au moins aussi rapide que l’évaluation humaine. Le temps passé par un opérateur sur cette inspection est variable. Indépendamment de l’opérateur lui-même, la rapidité d’exécution de cette tâche dépend notamment de :

- la taille de l’échantillon, c’est-à-dire la quantité de grains qui le constitue ;

- la nature et le nombre des critères d'inspection : taille, poids, défauts ;
- la taille des grains qui constituent l'échantillon : pour un humain, les grains sont d'autant plus délicats à isoler qu'ils sont de petite taille ; de fait, pour un système de vision, il est possible d'adapter les paramètres optiques.

En dehors de l'aspect temporel de cette opération, la difficulté au cours de cette évaluation est de parvenir à parfaitement caractériser les grains de l'échantillon. Il faut pour cela qualifier chacun de ses éléments, en d'autres termes, il est nécessaire d'évaluer chaque grain de céréale de manière individuelle. Cette inspection doit permettre de fournir en sortie des résultats simples qui dépendent du type d'application : proportions de classes de grains - selon leur taille et/ou leur forme (grains cassés et grains entiers par exemple) - selon la présence de défauts (tâches) - selon leur couleur moyenne.

Ces résultats sont obtenus après que le client ait défini clairement les classes qu'il souhaite distinguer au travers d'un apprentissage préalable de ces classes.

1.4 Problématiques

Le but n'est donc pas ici de mettre au point un appareil de mesure au sens purement métrologique du terme, même si les mesures doivent être aussi précises que possible, mais plutôt de concevoir un appareil de contrôle, permettant d'évaluer la qualité d'un produit depuis des critères de référence définis par le client pour son application (distribution de tailles, proportion de classes).

Les échantillons sont destinés à être observés sans arrangement (en "vrac") mais à plat de manière à éviter les recouvrements d'objets et donc les pertes d'informations. Les acquisitions sont réalisées dans une enceinte fermée assurant des conditions stables d'illumination.

L'évaluation par l'instrument se compose de trois phases :

- **Acquisition.** L'opérateur place les échantillons de manière aléatoire sur un plateau disposé sous le capteur optique dans l'enceinte et prend une image ;
- **Détection.** Le système doit identifier séparément chaque objet de l'image ;
- **Classification.** Les caractéristiques de chaque objet sont extraites et seront exploitées ensuite par le logiciel Alpha Soft, développé et commercialisé par Alpha MOS, pour traiter la classification.

Le résultat est alors déduit de la classification, la qualité de l'échantillon peut être déterminée et le prix fixé par l'industriel.

La détection est l'étape la plus délicate dans ce processus. Il est nécessaire de mettre au point une méthode de segmentation à même d'isoler chaque objet sous les contraintes suivantes :

- le nombre d’objets est inconnu (une vague estimation est cependant possible) ;
- les objets présentent des caractéristiques géométriques et chromatiques relativement génériques ;
- les objets sont disposés de manière aléatoire, non ordonnés, mais sans recouvrement.

L’entreprise Alpha MOS dispose déjà de solides connaissances, d’un savoir faire et d’outils en matière de classification de données. L’objectif principal des travaux menés dans le cadre de cette thèse est d’être en mesure d’extraire les données visuelles de manière individuelle d’un grand nombre d’objets de type grains de céréales. Les travaux se focalisent donc sur les méthodes d’acquisition et d’extraction de données visuelles. Ces données seront ensuite exploitées par l’entreprise qui souhaite par la suite mettre en avant des études multi-modalités en fusionnant les informations provenant de systèmes différents, l’objectif étant à terme d’être en mesure de qualifier la qualité d’un produit alimentaire quelconque (grains, mais aussi, fruits, légumes, gâteaux...) en considérant des critères olfactifs (odeur et goût) et visuels. Les travaux se concentrent sur les produits agroalimentaires de type grains de céréales, les problématiques posées par d’autres produits seront évoquées dans les perspectives de cette thèse.

1.5 Contraintes industrielles

Les développements menés dans le cadre de cette thèse sont destinés à un usage industriel. Les développements logiciels seront intégrés dans le logiciel Alpha Soft commercialisé par l’entreprise Alpha MOS. Ce logiciel, commun aux instruments distribués par l’entreprise, permet de traiter et de fusionner les données issues de différents systèmes. Il comprend notamment des outils statistiques utilisés pour traiter les problématiques de classification par une approche basée sur la méthode d’analyse en composante principale.

Afin de fournir des éléments exploitables industriellement par ce logiciel, les développements menés ont donc été implémentés en langage C et C++. Des tests préliminaires ont régulièrement été réalisés sous le logiciel Matlab, cela afin d’obtenir rapidement des programmes de tests utilisés pour explorer et valider la pertinence des directions choisies. Les bibliothèques de traitement d’images CImg [7] et OpenCV [40] ont été utilisées pour implémenter les travaux en langage C/C++. Les développements réalisés pour la partie apprentissage de modèles de forme et détection ont été intégrés dans une *dll* (Dynamic Link Library, ou bibliothèque de liens dynamiques en français) qui est appelée directement depuis le logiciel Alpha Soft. Les interfaces et développements mis en place pour la partie acquisition ont été directement implémentés dans le logiciel Alpha Soft. La durée maximale autorisée par l’entreprise pour traiter l’inspection visuelle d’un échantillon d’une centaine de grains de céréales ne doit pas excéder quelques minutes. La précision de détection demandée par les céréaliers pour l’inspection visuelle de grains est de 5%. En d’autres termes, il faut que le système soit capable de correctement détecter et analyser au moins 95% des grains de céréales sur chaque image.

1.6 Organisation

Le manuscrit est composé de trois chapitres majeurs et d'un chapitre qui étend les travaux présentés :

- le chapitre 2 présente le système d'acquisition qui a été mis au point et utilisé pour obtenir les images de grains présentées dans ce manuscrit, détaillant notamment les dispositifs d'éclairage et d'acquisition d'images, ainsi que les méthodes mises au point pour optimiser la qualité et la répétabilité des mesures ;
- le chapitre 3 présente la méthode d'apprentissage de modèles de forme conçue pour caractériser et modéliser les grains d'une application donnée, les modèles de forme pouvant être obtenus selon différentes modélisations depuis une forme moyenne dont la construction est détaillée ;
- le chapitre 4 présente les outils et les méthodes de détection ayant été mis au point pour réaliser la segmentation d'images de grains de céréales, les différentes étapes des deux approches, déterministe et probabiliste, y sont détaillées ;
- le chapitre 5 présente des exemples applicatifs exploitant les résultats fournis par les travaux exposés dans les chapitres précédents, puis s'intéresse aux débouchés que proposent ces travaux, notamment sur des acquisitions dans des domaines en dehors du visible.

Chapitre 2

Acquisition

Ce chapitre présente le système d’acquisition mis au point pour répondre à la problématique d’agrégage visuel de produits agroalimentaires de type grain de céréales. La première section (2.1) dresse l’état de l’art de différents systèmes d’acquisition disponibles sur le marché puis les solutions technologiques retenues pour le système mis au point dans le cadre de cette thèse sont présentées. La seconde section (2.2) s’intéresse à caractériser le système selon des critères tels que l’homogénéité de l’éclairage et l’homogénéité spatiale par exemple, afin de s’assurer de la capacité du système à fournir des images desquelles les résultats sont exploitables. Enfin, les différents moyens mis en œuvre pour optimiser la qualité et la répétabilité des acquisitions sont détaillés dans la dernière section (2.3).

2.1 Système d’acquisition

L’entreprise Alpha MOS disposait d’un précédent système d’acquisition d’images commercialisé depuis 2011. Ce système était destiné à réaliser l’acquisition d’images couleurs de produits de natures et de tailles variées. Les images étaient ensuite traitées pour extraire les informations couleurs du produit analysé. L’outil de statistiques multivariées développé par l’entreprise Alpha MOS permettait de traiter les données couleurs récoltées sur plusieurs produits afin de les comparer. Le système permettait ainsi d’établir par exemple :

- un ratio de gras/maigre sur des tranches de jambon blanc ;
- une proportion d’ingrédients dans une salade composée type taboulé ;
- la quantité de pépites de chocolat visibles sur un cookie.

Cependant, ce système n’était pas capable de traiter des problématiques à l’échelle d’objets si ces derniers n’étaient pas manuellement séparés par un opérateur. L’analyse restait donc globale et le nombre d’applications restreint. De plus, la séparation des objets un à un s’avère fastidieuse, particulièrement dans le cas de petits objets tels que des grains de riz.

Une problématique telle que l'agréage de grain de céréales nécessite la détection des objets de manière individuelle. Deux solutions sont envisageables :

- séparer les objets physiquement, cette opération pouvant être automatisée par l'utilisation d'un dispositif adéquat (bol vibrant, grille) ou réalisée manuellement par un opérateur ;
- être capable de détecter les grains au sein d'une image où ceux-ci ne sont pas organisés, la seule contrainte étant de limiter les recouvrements entre objets.

Le principal inconvénient de la première solution est qu'elle est spécifique à chaque type de grain. En effet, la taille, la forme et le poids des grains de céréales peuvent fortement varier selon l'application. La volonté de l'industriel étant de pouvoir offrir une solution générique, la seconde solution consistant à détecter les objets non séparés a été retenue.

Il est alors apparu nécessaire de modifier le système préexistant pour deux principales raisons : améliorer les performances et combler les lacunes du précédent système, en ne s'interdisant néanmoins aucunement d'orienter le choix des composants afin d'adapter le système à notre problématique. Ces modifications ont cependant dû être opérées en tenant compte des contraintes fixées par l'industriel : coût, facilités d'intégration, de maintenance et de mise en production. En effet, le coût du système devait rester sensiblement identique à sa version précédente ; le châssis de l'instrument devait être conservé, seuls les éléments internes et leurs dispositions pouvaient être modifiés. Les changements apportés sont présentés dans les sections suivantes.

2.1.1 Marché

Destiné à être utilisé hors ligne, le système réalise des prises de vue statiques des objets à analyser. Dans le but d'être imperméable aux perturbations extérieures, notamment en matière de pollution lumineuse, il est nécessaire de placer les objets dans une cabine close de type cabine à lumière. Ainsi, le système doit offrir des conditions d'acquisition indépendantes de l'environnement lumineux extérieur et doit permettre d'obtenir des conditions d'acquisitions stables, à des moments et dans des environnements différents.

Dans le domaine du contrôle qualité visuel, il existe de nombreux fabricants de cabines à lumière : Pantone [42], Verivide [56], X-Rite [60] et TQC Colorbox [8] (figure 2.1). Ces enceintes lumineuses sont cependant destinées à un contrôle visuel réalisé par un opérateur humain : l'enceinte n'est pas close. L'opérateur dispose le produit à contrôler dans l'enceinte et le compare généralement à un étalon sous un illuminant donné. Ces cabines à lumière offrent un environnement à éclairage contrôlé avec plusieurs types d'illuminants disponibles (lumière du jour D65, fluorescent à spectre étroit TL84, rayonnement ultraviolet UV, ...). Ces dispositifs ne sont cependant pas adaptés à l'usage que nous souhaitons en faire, ils sont sensibles aux perturbations lumineuses éventuelles de l'environnement dans lequel se trouve la cabine. D'autre part, ils ne sont pas pourvus

de dispositifs d'acquisition.




FIGURE 2.1 – Exemples de cabines à lumière.

La société Verivide [14] commercialise par ailleurs une enceinte lumineuse close, intégrant un dispositif d'acquisition d'images numériques (figure 2.2). Un appareil photographique de type reflex intégré dans la partie haute de la cabine à lumière est utilisé pour les acquisitions. L'enceinte est fermée durant les acquisitions, l'ouverture et la fermeture de la cabine sont assurées par un dispositif motorisé. Un logiciel, installé sur un ordinateur relié à l'appareil, permet de réaliser les acquisitions et de traiter les données. Ce système est particulièrement adapté à l'analyse colorimétrique de divers produits, mais ne permet pas de traiter efficacement la problématique d'agrégage visuel ; il n'existe en effet pas de fonction de détection d'objets présentés en vrac, seule une estimation sur la globalité des objets est possible, sans tenir compte de chaque objet de manière individuelle. Cela peut permettre de donner une tendance sur la qualité globale d'un lot de grains [23, 55], sans être en mesure de donner des proportions à l'échelle individuelle. Pour traiter la problématique d'agrégage visuel telle que l'industriel le souhaite, à savoir offrir un système capable d'extraire des données à l'échelle d'un grain, nous devons donc mettre au point notre propre système.



FIGURE 2.2 – DigiEye Verivide.

2.1.2 Enceinte

Le châssis du système préexistant au sein de l'entreprise Alpha MOS a été conservé et n'a pas subi de modification, comme le souhaitait l'entreprise. Il se compose d'une enceinte, également appelée cabine à lumière, dans laquelle sont placés les échantillons à analyser. On distingue trois zones (figure 2.3). Les parties supérieure (2) et inférieure (3) sont des compartiments non accessibles et non visibles pour l'opérateur, dans lesquels sont disposés le dispositif d'éclairage (2 et 3) et la caméra (2). Cette architecture permet ainsi une configuration d'éclairage modulable : les éclairages supérieur et inférieur sont commandés de manière indépendante. Les compartiments (2) et (3) sont séparés de la zone d'acquisition (1) par des diffuseurs dont le rôle est d'assurer une propagation homogène de la lumière émise par le dispositif d'éclairage dans la zone (1), tout en limitant l'effet de baisse sur son intensité et en préservant ses propriétés spectrales, la matière des diffuseurs laissant en effet passer les longueurs d'ondes concernées selon les données fabricant. Un trou circulaire permet de laisser passer l'optique de la caméra afin qu'il n'y ait aucun obstacle entre les objets disposés sur le plateau et le capteur de la caméra (figure 2.4). Les diffuseurs n'ont également pas été modifiés.




FIGURE 2.3 – Système d'acquisition des images IRIS.

La partie centrale est la zone d'acquisition, les échantillons à analyser sont disposés sur un plateau. Le plateau peut être adapté en fonction de la nature des échantillons à analyser ; plusieurs modèles sont disponibles, de couleur homogène (noir, blanc, bleu). On privilégie le plateau dont la couleur présente le contraste le plus important avec les échantillons, ceci dans le but de faciliter les traitements appliqués à l'image durant les étapes de détection, notamment la séparation du fond et des objets. Le plateau est inséré dans une glissière, ce qui permet à l'opérateur de pouvoir le déplacer vers l'extérieur de l'enceinte afin de disposer les échantillons de manière plus ergonomique.



FIGURE 2.4 – Disposition de la caméra et de son optique.



FIGURE 2.5 – Brique de 4 LEDs blanches.

2.1.3 Éclairage

Le système d'éclairage de la cabine a été remplacé. Le précédent système était composé de tubes fluorescents présentant un spectre type lumière du jour (D65). Cette solution est également celle retenue par de nombreux fabricants de cabines à lumière, mais elle souffre de certains défauts. Les tubes fluorescents nécessitent notamment un temps de chauffe non négligeable, de l'ordre de 15 à 20 minutes selon les modèles et les fabricants. Malgré le respect de ce délai, la stabilité de cet illuminant est également problématique, des variations non négligeables sont observables. De plus, la durée de vie des tubes fluorescents, de l'ordre de 2000 à 3000 heures, nécessite de les remplacer régulièrement. L'utilisation de tubes fluorescents requiert également une source de tension de 220 volts, dont il faut contrôler la stabilité et à laquelle il faut associer des dispositifs spéciaux : starters et ballastes, nécessaires à l'alimentation correcte des tubes. Tous ces éléments rendent le dispositif assez complexe à mettre en place. Enfin, la manipulation et le déplacement des tubes fluorescents sont problématiques, ils nécessitent une manipulation minutieuse du fait de leur fragilité.

Notre choix pour le nouveau dispositif d'éclairage s'est alors porté vers une solution composée de briques LED (figure 2.5). La solution LED a été retenue pour plusieurs raisons. Tout d'abord, les LED blanches fabriquées aujourd'hui présentent une répartition spectrale qui couvre l'ensemble des longueurs d'onde du visible de manière continue (figure 2.6), dont le rendu des couleurs est tout à fait adapté à un système de contrôle qualité par imagerie numérique [46]. Un autre intérêt est que cette solution ne nécessite pas de temps de chauffe pour être opérationnelle, contrairement aux solutions de type tube fluorescent. D'un point de vue industriel, le produit est robuste, notamment en cas de déplacement de l'instrument, et l'intégration de ces briques ne présentent pas de contraintes majeures. Enfin, la technologie LED présente des intérêts non négligeables :




FIGURE 2.6 – Répartition spectrale des LED blanches.

une faible consommation, inférieure à 6 watts par brique, alimentée en 24 volts, et une durée de vie importante, supérieure à 50 000 heures.

Chaque brique comporte quatre LED blanches. Les briques sont fixées sur des plaques (figure 2.7), qui sont ensuite disposées dans l'enceinte d'acquisition. Quatre briques LED sont montées sur chaque plaque, inférieure et supérieure. Il convient de préciser que l'illuminant principal est le dispositif supérieur. Le dispositif inférieur est utilisé pour minimiser la présence d'éventuelles ombres et ne peut l'être qu'avec le plateau blanc ; les deux autres plateaux, noir et bleu, étant opaques. Le choix du nombre et de la disposition des briques LEDs est justifié dans la section 2.2.2.




FIGURE 2.7 – Plaques inférieure (gauche) et supérieure (droite).

2.1.4 Dispositif d'acquisition

La caméra a été elle aussi remplacée. L'ancienne caméra était un modèle couleur mono capteur CCD de 1/3 inch, de $1\,024 \times 768$ pixels, à focale motorisée variable ($f = 5$ à 45 mm). Nous avons identifié un défaut de positionnement du diaphragme motorisé, nuisant à la capacité de cette caméra à fournir des mesures répétables. Ce modèle n'était pas adapté à la problématique et souffrait d'une obsolescence courante sur ce marché en perpétuelle évolution. La caméra que nous avons choisie d'intégrer dans le système est une caméra mono capteur CMOS de 5 millions de pixels ($2\,590 \times 1\,942$) associée à une optique à focale fixe. Malgré des performances intéressantes, les caméras tri-CCD, parfaitement adaptées à de l'imagerie couleur, n'ont pas pu être retenues, leurs coûts demeurant encore trop élevés. Le capteur CMOS retenu, de 1/2.5 inch, couplé à un filtre de Bayer, permet la construction d'images couleur.

Il a été choisi de conserver la méthode de démosaïquage optimisée par le constructeur, la mise en œuvre d'une autre méthode ne représentant a priori pas un réel enjeu dans le cadre de notre problématique, la méthode du constructeur étant par ailleurs jugée satisfaisante. Les images sont enregistrées au format PNG, permettant ainsi une compression sans perte d'information, et encodées sur 24 bits (3 canaux RGB, à raison de 8 bits par canal). La caméra est reliée à une unité de traitement (ordinateur portable) via une connectique Ethernet. Sauf contre indication, les acquisitions présentées dans ce manuscrit ont été réalisées avec une optique à focale fixe de 5 mm, dont les réglages d'ouverture de diaphragme et de mise au point sont manuels : deux bagues permettent de les régler et deux vis de bloquer leurs positions. L'optique peut être adaptée en fonction de la nature des échantillons à analyser, différentes focales sont disponibles (8, 10, 12, 14 et 16 mm).

La caméra est placée à 400 mm du plan objet constitué par le plateau. Dans cette configuration (optique de focale 5 mm), la résolution est d'environ 6 pixels par millimètre, compatible avec l'évaluation d'objets tels que les grains de céréales qui mesurent quelques millimètres au minimum. Le champ de vue est alors de 450 par 300 mm.

2.2 Caractéristiques du système d'acquisition

Cette section présente les caractéristiques du système d'acquisition ayant un impact fort sur la qualité des images qui seront acquises avec ce système, et donc sur les résultats.

2.2.1 Distorsion

La distorsion est une aberration géométrique entraînant des déformations au sein de l'image. Ces déformations peuvent être en barillet, c'est à dire que des supposées droites apparaissent incurvées vers le centre de l'image, ou en coussinet, les supposées droites apparaissent alors incurvées vers l'extérieur de l'image. La distorsion trouve plusieurs origines : l'ouverture du diaphragme ou la qualité de l'optique notamment. Afin de

quantifier cette déformation sur le système d’acquisition mis au point, des mesures ont été réalisées. Du papier millimétré au format A3 a été utilisé (figure 2.8).




FIGURE 2.8 – Image utilisée pour le calcul de distorsion.

La distorsion est alors évaluée en considérant les lignes du quadrillage les plus éloignées du centre. Les mesures obtenues ainsi que la distorsion moyenne associée sont présentées dans la table 2.1. On obtient quatre valeurs : horizontale haut et bas, verticale gauche et droite. On mesure ces quatre valeurs pour prendre en compte l’hypothèse que l’axe de la caméra n’est pas parfaitement perpendiculaire au plan objet, la distorsion peut être asymétrique : les distances au plan objet ne sont pas les mêmes pour deux points situés symétriquement autour de l’intersection entre l’axe de la caméra et le plan objet. On obtient finalement une valeur moyenne pour la distorsion de 0.28 : il existe donc une faible distorsion mais celle-ci reste d’influence minime, comme nous le vérifierons dans la section sur l’homogénéité spatiale (2.2.4).

Distorsion horizontale (haut)	0.32
Distorsion horizontale (bas)	0.25
Distorsion verticale (gauche)	0.23
Distorsion verticale (droite)	0.33
Distorsion moyenne	0.28

TABLE 2.1 – Valeurs obtenues pour le calcul de la distorsion.

2.2.2 Géométrie et homogénéité d’éclairage

L’homogénéité lumineuse dans la zone d’acquisition est un élément essentiel. Les objets ne doivent en effet pas être perçus différemment en fonction de leur position dans

l'image. Le choix de la géométrie d'éclairage est donc primordial. Afin de déterminer quelle était la meilleure configuration, une étude a été réalisée pour fixer le nombre optimal de plaques LEDs nécessaires ainsi que leur disposition. Pour cela, un luxmètre (figure 2.9) a été utilisé. Des mesures de luminosité ont ainsi été relevées en différents points de la zone d'acquisition. Ces mesures ont été réalisées avec l'optique de focale 5 mm, le champ de vue étant le plus important avec cette optique. La figure 2.10a illustre l'expérience : le luxmètre est placé à la position voulue, puis la porte de l'enceinte est refermée et l'image enregistrée, permettant de lire a posteriori la valeur mesurée.




FIGURE 2.9 – Luxmètre Testo 540 utilisé pour les mesures d'homogénéité d'éclairage.

Différentes configurations ont été étudiées en faisant varier :

- le nombre de plaques LEDs utilisées ;
- leurs positions relatives (écartements entre les plaques) ;
- leur distance par rapport au diffuseur.

Finalement, l'exploitation des mesures a permis de déterminer la configuration offrant la meilleure homogénéité d'éclairage. Elle se compose, pour l'éclairage par le haut tout comme pour celui par le bas, de 4 plaques LEDs disposées chacune dans un quartier de la zone d'acquisition (figure 2.7). Les mesures d'homogénéité d'éclairage associées à cette configuration sont présentées sur la figure 2.10b, les valeurs sont données en pourcentage relatif de l'intensité lumineuse maximum mesurée. On s'aperçoit que l'homogénéité est correcte dans la zone centrale, contrairement aux zones éloignées, et plus particulièrement les coins inférieurs. On privilégiera donc de façon classique d'exploiter majoritairement la zone centrale pour réaliser les acquisitions.

Une alternative répandue pour un éclairage diffus est la géométrie de type dôme : l'éclairage n'est pas direct mais renvoyé par une surface dont le revêtement et la géométrie sont adaptés. Mais dans la mesure où il était nécessaire pour l'industriel d'avoir



(a)

95	98	99	97	94
96	99	100	99	96
95	98	99	98	95
93	96	97	96	93
91	93	94	94	91

(b)

FIGURE 2.10 – Images de mesures de l’homogénéité de l’éclairage en différents points de la zone d’acquisition (2.10a) et mesures associées (2.10b), les valeurs sont en pourcentage relatifs par rapport à la valeur maximum.

des compartiments interdisant l’accès aux éléments (éclairage, bloc caméra), la solution des diffuseurs a été retenue. Cette solution est également plus compacte en terme d’encombrement, la mise en place d’un dôme nécessitant plus de recul.

2.2.3 Stabilité de l’éclairage

La stabilité à travers le temps du système d’éclairage est importante afin de garantir la répétabilité des mesures. Afin d’évaluer cette stabilité, une étude basée sur la mesure de l’éclairement lumineux a été réalisée. Le luxmètre a été placé dans l’enceinte pendant 6 heures et une image permettant de lire la valeur indiquée a été prise toutes les 30 secondes. L’évolution de cette mesure (figure 2.11) confirme que la solution LED offre des conditions d’éclairage particulièrement stables, la seule variation notable étant observée durant les 5 premières minutes mais celle-ci reste mineure : à l’allumage le luxmètre

mesure 1765 lux pour ensuite se stabiliser autour de 1740 lux. L'évolution de l'éclairement lumineux des tubes fluorescents utilisés dans le système précédent par l'entreprise Alpha MOS est présentée en figure 2.12 pour comparaison. La différence majeure entre les deux solutions est donc la stabilité des LEDs dont l'éclairement lumineux est stable quelques minutes après la mise sous tension, alors que des variations sont observées tout au long des 6 heures de mesures pour la solution tubes fluorescents.




FIGURE 2.11 – Évolution de l'éclairement lumineux des LEDs blanches.

On peut également souligner la stabilité de l'éclairement lumineux qu'offre cette solution (figure 2.11), ce qui représente un aspect essentiel en vue d'assurer la répétabilité des mesures fournies par le système.

2.2.4 Homogénéité spatiale

Une fois acquis que les conditions d'éclairage sont significativement homogènes dans la zone d'acquisition, il faut s'assurer que le système soit capable de mesurer de manière identique deux objets situés à des emplacements différents de la zone d'acquisition. Un support imprimé de 24 formes identiques (figure 2.13) a été utilisé, toujours au format A3, afin de couvrir la totalité du champ de vue. Une fois l'image enregistrée, une binarisation de l'image a été réalisée. Différents paramètres ont ensuite été obtenus pour chaque objet : aire, grand axe et petit axe. Ces deux derniers paramètres sont les valeurs de longueur d'axe obtenues en modélisant un objet par une ellipse, la méthode utilisée est décrite dans la section 3.3.2. Les résultats sont présentés dans la table 2.2.

Les valeurs mesurées pour chacune des formes circulaires sont stables, l'écart type est faible, équivalent à environ 1% de la valeur moyenne. Cette variation peut aussi




FIGURE 2.12 – Évolution de l'éclairement lumineux de tubes fluorescents.




FIGURE 2.13 – Image de 24 formes circulaires identiques.

s'expliquer par la méthode d'extraction des objets et la discrétisation du contour à l'échelle pixelique, mais ne présente pas un inconvénient majeur à l'exploitation du système dans le cadre de notre problématique.

2.3 Optimisation des acquisitions

Dans le but d'optimiser la qualité des acquisitions d'une part, et d'assurer la répétabilité et la reproductibilité du système d'autre part, deux méthodes ont dûes être mises en place et sont présentées dans les deux sections suivantes. La première section s'intéresse au débruitage des images enregistrées. La seconde présente la méthode d'éta-lonnage colorimétrique conçue pour assurer répétabilité et reproductibilité des mesures du système.

Numéro objet	Aire	Grand axe	Petit axe
1	20249	159	159
2	20033	159	158
3	19930	158	158
4	19766	158	157
5	19702	157	157
6	19652	158	156
7	20189	159	159
8	20102	159	158
9	19985	158	158
10	19857	158	157
11	19724	157	157
12	19529	157	156
13	20051	159	158
14	19709	157	157
15	19605	157	156
16	20180	159	158
17	19993	158	158
18	19867	158	157
19	19732	158	157
20	19596	157	156
21	19928	158	158
22	19821	158	157
23	20203	159	159
24	20060	159	158
Moyenne	19894.3	158.1	157.5
Écart type	212.6	0.78	0.93

TABLE 2.2 – Mesures relevées (aire, grand axe et petit axe), moyennes et écarts type des 24 formes circulaires.

2.3.1 Débruitage

Tout d’abord, afin d’optimiser la qualité des acquisitions obtenues avec le matériel présenté dans la section précédente, et plus particulièrement pour limiter l’impact des différents types de bruit (notamment du bruit blanc), l’image enregistrée est la moyenne de plusieurs acquisitions successives. L’impact du bruit aurait pu être encore réduit en utilisant des composants (caméra, optiques) haut de gamme mais dont le coût n’était pas compatible avec le cahier des charges fixé par l’industriel.

Afin de déterminer le nombre optimal d’images qu’il est nécessaire de considérer pour créer l’image moyenne, des tests ont été réalisés avec des images moyennées sur une à dix acquisitions successives (figure 2.14). Ces images ont ensuite été comparées avec une image obtenue en considérant la moyenne des dix images préalablement filtrées par un filtre médian de taille 3×3 . Ces tests sont effectués sans échantillon présent dans l’enceinte, en utilisant le plateau noir. Le but étant d’obtenir des images les plus homogènes possible, l’utilisation du filtrage médian peut être considérée pour définir une référence.

Le filtre médian ne constitue cependant pas une solution applicable lors d'acquisitions avec des échantillons. En effet, l'usage de ce filtre non linéaire engendrerait des pertes d'informations non acceptables comme par exemple l'éventuelle disparition de tâches de petites tailles sur un échantillon. Afin d'observer visuellement la diminution du bruit, les figures 2.14 et 2.15 incluent des images notées $D(i)$, obtenues en considérant la différence moyenne sur les trois canaux RGB entre l'image $M(i)$ et l'image de référence notée $M(\text{median}(10))$.




FIGURE 2.14 – Affichage graphique de l'évolution d'une zone de pixels en fonction du nombre d'images moyennées : de une ($D(1)$) à dix ($D(10)$) acquisitions.

Les tests menés ont permis de trouver un compromis entre qualité de débruitage par moyennage et rapidité d'exécution. La figure 2.16 illustre les résultats obtenus en considérant pour dix acquisitions successives : d'une part les images brutes (rouge) et d'autre part les images médianes (noir) et moyennes (bleu) construites depuis une à dix acquisitions. On considère le pourcentage de pixels dont la distance couleur RGB (équation 2.3), calculée par rapport à l'image obtenue par filtrage médian, est supérieure à cinq. Sur les images brutes, le pourcentage est relativement constant : environ 12.5% des pixels présentent une distance supérieure à cinq, sur une échelle comprise entre 0 et 255, par rapport à l'image utilisée comme référence. En considérant moyenne et médiane, ce taux décroît rapidement.

Il a finalement été décidé de considérer la moyenne sur six images successives (figure 2.15), le taux étant alors d'environ 1%. Toutes les images traitées par le système sont obtenues de cette manière, y compris lors de l'étalonnage radiométrique (figure 2.17).

2.3.2 Étalonnage colorimétrique

Afin d'assurer la reproductibilité et la répétabilité des acquisitions, il est apparu nécessaire de mettre au point une méthode d'étalonnage radiométrique. L'étalonnage est réalisé en s'appuyant sur une charte 24 couleurs X-Rite Colorchecker[®] Classic (figure 2.18). L'opérateur est invité par le logiciel à procéder à l'étalonnage radiométrique




FIGURE 2.15 – Zoom sur l'image brute ($M(1)$) et moyenne sur 6 images ($M(6)$), ainsi que leurs représentation graphique ($D(1)$ et $D(6)$), et image moyenne de 10 images filtrées par un filtre médian de taille 3×3 ($M(\text{median}(10))$) utilisée comme référence.

du système toutes les 24 heures à minima, afin de s'assurer que tous les composants du système fonctionnent correctement et ne pas compromettre les mesures réalisées sur une durée trop importante. À l'issue du processus d'étalonnage, les paramètres obtenus sont enregistrés et utilisés pour réaliser les acquisitions jusqu'au prochain étalonnage.

La méthode implémentée est composée de trois étapes :

- réglage du diaphragme ;
- balance des blancs ;
- matrice de correction.

La première consiste à s'assurer que le diaphragme est correctement positionné et à guider l'opérateur dans ce réglage le cas échéant. Les conditions d'acquisitions contrôlées permettent de connaître les valeurs de luminance optimales pour les six nuances de gris de la charte ; le réglage du diaphragme a donc pour but d'obtenir ces valeurs. Pour cela, l'opérateur suit les consignes données par l'assistant logiciel, pour ouvrir ou fermer le diaphragme jusqu'à obtention du réglage correct (figure 2.20).

La balance des blancs est la deuxième étape de l'étalonnage. L'échelle de six nuances de gris de la charte est de nouveau utilisée. Le but de cette étape est d'équilibrer les poids des différents canaux de manière à obtenir des couleurs neutres pour les six nuances de gris ; en d'autres termes, les valeurs r , g , b des trois canaux doivent être égales.

La dernière étape consiste à calculer une matrice de correction couleur (CCM). Les 24 couleurs de la charte sont cette fois prises en compte. On confronte les valeurs mesurées pour chacune des couleurs avec leurs valeurs théoriques. Ces valeurs théoriques sont considérées comme les valeurs optimales sous l'illuminant LED et sont utilisées comme références. Une matrice M de correction couleur de taille 3×3 est calculée à partir des




FIGURE 2.16 – Influence du nombre d'images pour le calcul d'une image moyenne.

valeurs théoriques et des valeurs mesurées.

$$\left\{ \begin{array}{l} M = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix} \\ \begin{bmatrix} r_{ref_i} \\ g_{ref_i} \\ b_{ref_i} \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix} \begin{bmatrix} r_{mes_i} \\ g_{mes_i} \\ b_{mes_i} \end{bmatrix} \text{ pour } i = 1, 2, \dots, 24 \end{array} \right. \quad (2.1)$$

Afin de déterminer les coefficients a_{ij} de la matrice de correction couleur, on dispose de 24 équations de triplets $\{r, g, b\}$ dont on connaît les valeurs de référence et les valeurs mesurées par le système (équation 2.1). Ce système surdéterminé est résolu en utilisant la méthode des moindres carrés par décomposition en valeurs singulières SVD [24]. Les coefficients de la matrice de correction couleur obtenus sont alors appliqués systématiquement, seules les valeurs $\{r_c, g_c, b_c\}$ sont désormais considérés (équation 2.2).

$$\begin{bmatrix} r_c \\ g_c \\ b_c \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix} \begin{bmatrix} r \\ g \\ b \end{bmatrix} \quad (2.2)$$



FIGURE 2.17 – Couleurs 8, 14, 15 et 16 de la charte extraites depuis l’image brute (à gauche) et depuis l’image moyennée (à droite), telles qu’elles sont utilisées lors de l’étalonnage radiométrique.

2.3.3 Mesures

De nombreux travaux reposent sur la problématique des distances couleur optimales [34, 45, 54]. Deux semblent consensuelles et encore de référence dans le monde industriel : les distances couleur d_1 (équation 2.3) et d_2 (équation 2.4), respectivement définies dans les espaces couleur sRGB et CIE Lab. Une distance couleur est alors définie comme la distance euclidienne entre deux couleurs C_1 et C_2 dans l’espace considéré.

$$d_1(C_1, C_2) = \sqrt{(r_1 - r_2)^2 + (g_1 - g_2)^2 + (b_1 - b_2)^2} \quad (2.3)$$

$$d_2(C_1, C_2) = \Delta E_{76} = \sqrt{(L_1 - L_2)^2 + (a_1 - a_2)^2 + (b_1 - b_2)^2} \quad (2.4)$$

Ces distances ont été considérées pour effectuer des tests visant à quantifier la reproductibilité et la répétabilité de la méthode d’étalonnage. Cette méthode définit les paramètres d’acquisition qui sont utilisés pour toutes les prises d’images, il est donc important que celle-ci présente des capacités de reproductibilité et de répétabilité optimales. Les tests réalisés sont basés sur l’acquisition d’images de la charte à différents instants, par différents systèmes. Les valeurs des 24 couleurs de la charte sont alors extraites sur chacune des images. Les résultats présentés visent à comparer deux images de charte acquises à des moments différents et/ou par des instruments différents. Pour cela, on synthétise la comparaison sous la forme d’une distance couleur ΔE_{76} moyenne prenant en compte les 24 couleurs de la charte sur deux images distinctes.

La première série de tests tend à quantifier la répétabilité : il s’agit de caractériser la capacité d’un système donné à reproduire des mesures dans des conditions identiques. Des




FIGURE 2.18 – Charte 24 couleurs X-Rite ColorChecker® Classic .

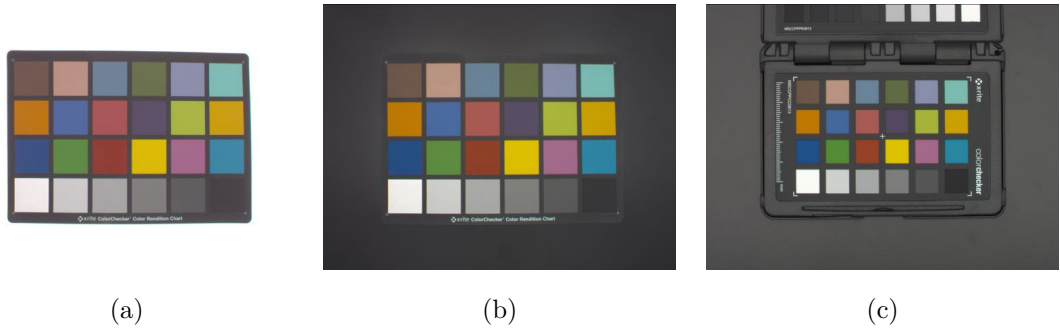


FIGURE 2.19 – X-Rite Colorchecker® Classic, focale 5mm : plateau blanc (a) et plateau noir (b). X-Rite Colorchecker® Passport, focale 12mm : plateau noir (c).

mesures ont été relevées ponctuellement sur un intervalle de temps court : 60 minutes (figure 2.21), puis sur un intervalle de temps plus long : 3 jours (figure 2.22).

La figure 2.23 illustre l'évolution des mesures par rapport à une mesure initiale faite à l'instant $t=0$, les mesures ayant étant faites en continu toutes les 10 minutes sur une période de 15 heures. On constate que la dérive maximale en distance couleur moyenne sur une durée de 15 heures est inférieure à 0.3, ce qui conforte la capacité du système à être répétable. On observe cependant une dérive qui augmente de manière lente mais continue. Une cause de cette dérive peut être la montée en température du capteur CMOS de la caméra. L'utilisateur du système est invité par le logiciel à procéder à l'étalonnage colorimétrique du système tous les jours, cela permet de corriger cette dérive.

La reproductibilité a ensuite été évaluée : en considérant deux systèmes différents, leurs mesures ont été comparées (figure 2.24).

Les résultats ont finalement été synthétisés dans la table 2.3. L'écart maximum en terme de distance couleur ΔE_{76} pour un même système est de 1.8, tandis que l'écart observé entre deux systèmes différents est de 2.9. Ces valeurs confortent la capacité de l'approche d'étalonnage radiométrique à être répétable et reproductible.

		Système A								Système B							
		Jour 1				Jour 2				Jour 3				Jour 1			
Système A		H_1	H_2	H_3	H_4	H_1	H_2	H_3	H_4	H_1	H_2	H_3	H_4	H_1	H_2	H_3	H_4
Système A	Jour 1	H_1	0.0	1.0	1.8	0.8	0.9	0.9	1.1	1.0	0.7	0.7	0.8	0.8	0.9	0.9	2.9
		H_2	1.0	0.0	1.3	0.4	0.2	0.6	0.7	0.4	0.6	0.5	0.6	0.4	0.4	2.5	
		H_3	1.8	1.3	0.0	1.6	1.3	1.8	1.8	1.7	1.6	1.5	1.8	1.7	1.6	2.4	
		H_4	0.8	0.4	1.6	0.0	0.4	0.4	0.5	0.3	0.7	0.4	0.4	0.3	0.2	2.7	
	Jour 2	H_1	0.9	0.2	1.3	0.4	0.0	0.6	0.7	0.5	0.6	0.3	0.6	0.4	0.4	2.5	
		H_2	0.9	0.6	1.8	0.4	0.6	0.0	0.2	0.3	0.9	0.5	0.2	0.4	0.3	2.8	
		H_3	1.1	0.7	1.8	0.5	0.7	0.2	0.0	0.4	1.0	0.6	0.3	0.5	0.4	2.9	
		H_4	1.0	0.4	1.7	0.3	0.5	0.3	0.4	0.0	0.7	0.5	0.4	0.2	0.1	2.7	
	Jour 3	H_1	0.7	0.6	1.6	0.7	0.6	0.9	1.0	0.7	0.0	0.6	0.8	0.6	0.7	2.6	
		H_2	0.7	0.5	1.5	0.4	0.3	0.5	0.6	0.5	0.6	0.0	0.4	0.4	0.4	2.7	
		H_3	0.8	0.6	1.8	0.4	0.6	0.2	0.3	0.4	0.8	0.4	0.0	0.4	0.4	2.8	
		H_4	0.8	0.4	1.7	0.3	0.4	0.4	0.5	0.2	0.6	0.4	0.4	0.0	0.2	2.7	
Système B		H_5	0.9	0.4	1.6	0.2	0.4	0.3	0.4	0.1	0.7	0.4	0.4	0.2	0.0	2.7	
	Jour 1	H_1	2.9	2.5	2.4	2.7	2.5	2.8	2.9	2.7	2.6	2.7	2.8	2.7	2.7	0.0	

TABLE 2.3 – Synthèse des tests d'étalement radiométrique : distance couleur ΔE_{76} moyen sur les 24 couleurs de la charte, comparaison des résultats sur 3 jours différents (J_1, J_2, J_3), à des heures différentes (H_1, H_2, H_3) et deux systèmes différents (S_A, S_B).

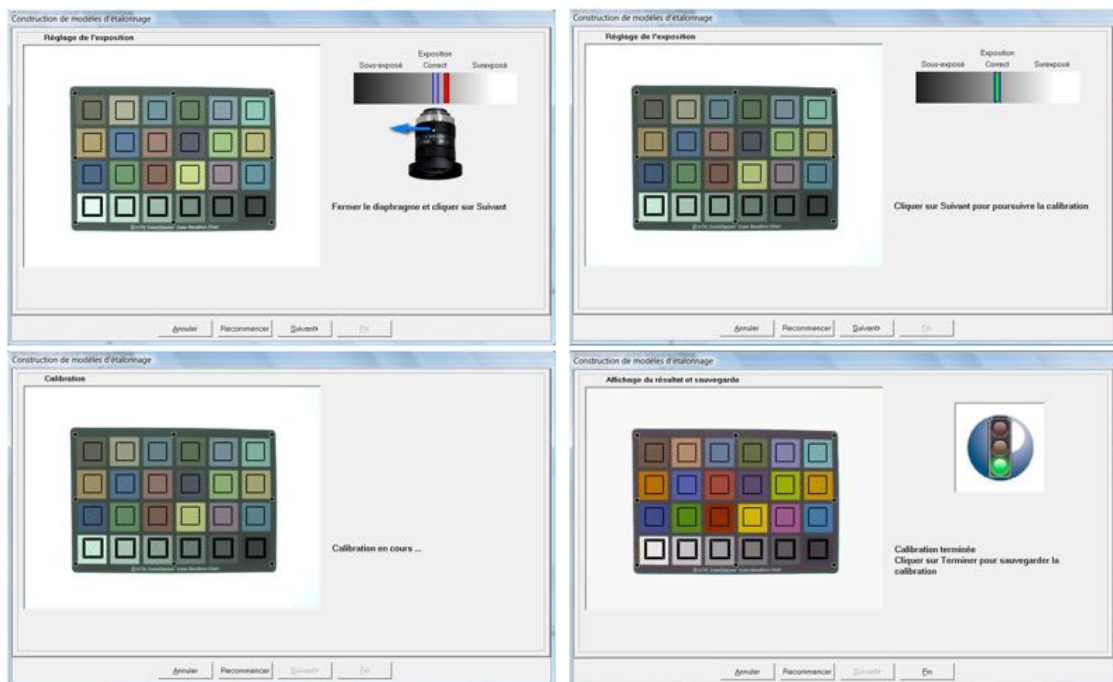


FIGURE 2.20 – Illustration de l'assistant d'étalonnage radiométrique intégré dans le logiciel.

Couleur	2 min			15 min			30 min			60 min			Ref		
	B	G	R	B	G	R	B	G	R	B	G	R	B	G	R
1	81	93	117	81	92	117	80	92	117	80	92	116	82	94	119
2	127	147	186	126	146	186	126	146	185	126	145	185	128	149	189
3	154	130	105	153	129	105	152	129	105	152	129	104	155	132	107
4	80	113	105	79	112	105	79	112	105	79	111	104	80	114	107
5	170	139	136	168	138	136	168	138	136	168	138	135	171	141	139
6	176	180	120	175	179	120	174	179	120	174	178	119	178	182	122
7	4	120	193	3	119	192	3	119	192	3	118	191	3	121	195
8	161	108	77	159	108	77	159	108	77	158	107	77	162	110	79
9	85	89	173	83	88	173	83	88	172	83	87	171	85	90	175
10	106	79	93	105	79	93	104	79	93	104	78	92	107	81	95
11	69	180	167	69	179	167	68	179	167	69	178	166	70	182	170
12	25	157	200	21	156	200	20	155	199	20	154	198	21	158	203
13	135	85	57	134	85	57	133	85	57	133	84	56	136	87	59
14	63	144	84	63	144	85	62	143	84	63	142	84	64	146	86
15	37	61	150	35	60	149	34	60	149	36	60	148	37	62	151
16	7	193	220	5	192	219	4	191	219	5	190	218	4	195	223
17	142	102	164	140	101	164	139	101	164	139	100	163	142	103	167
18	160	131	54	159	130	53	158	130	53	158	130	51	162	133	54
19	244	243	240	242	242	240	241	241	240	241	241	239	245	245	243
20	204	204	201	203	203	201	202	203	201	202	202	200	206	206	204
21	168	167	165	166	166	165	166	166	165	165	165	164	169	169	168
22	129	128	129	128	127	128	128	127	128	127	126	128	130	129	131
23	96	92	94	95	92	94	95	92	94	95	91	94	97	94	96
24	70	64	70	69	64	70	69	64	70	68	63	69	71	66	72

FIGURE 2.21 – Mesures sur 60 minutes.

Couleur	J1			J2			J3		
	B	G	R	B	G	R	B	G	R
1	83	94	117	80	92	116	81	92	117
2	130	149	186	126	145	185	127	146	186
3	155	131	102	152	129	104	153	129	105
4	80	113	103	79	111	104	79	112	105
5	171	140	134	168	138	135	168	138	136
6	178	181	115	174	178	119	175	179	119
7	6	123	192	3	118	191	3	119	192
8	162	109	74	158	107	77	160	108	77
9	87	91	172	83	87	171	84	88	173
10	106	80	93	104	78	92	105	79	93
11	68	181	164	69	178	166	70	179	167
12	30	158	199	20	154	198	21	155	199
13	136	86	55	133	84	56	134	85	57
14	63	145	80	63	142	84	64	143	84
15	41	64	149	36	60	148	36	60	149
16	11	195	219	5	190	218	6	191	219
17	143	104	164	139	100	163	140	101	164
18	161	132	45	158	130	51	159	130	52
19	246	246	238	241	241	239	243	242	241
20	206	207	199	202	202	200	204	204	201
21	169	169	163	165	165	164	167	167	165
22	130	129	128	127	126	128	128	127	129
23	97	93	94	95	91	94	95	92	94
24	70	65	70	68	63	69	69	63	70

FIGURE 2.22 – Mesures sur 3 jours.




FIGURE 2.23 – Évolution de la distance couleur ΔE_{76} par rapport à la mesure initiale $t=0$.



FIGURE 2.24 – Résultat d'étalonnage sur deux systèmes différents : système A à gauche, système B à droite.

Chapitre 3

Apprentissage de modèles de forme

Cette étape est réalisée en amont de la détection et certaines notions détaillées ici sont nécessaires à la bonne compréhension du chapitre 4. Tout d'abord, rappelons deux objectifs inhérents au système :

- le système doit permettre d'évaluer la qualité d'un lot de grains de céréales ;
- le système doit être en mesure de détecter chaque grain dans une image en comportant plusieurs dizaines voire des centaines, l'entreprise Alpha MOS ayant fixé le nombre de grains pour les tests numériques à 100.

En d'autres termes, il est tout d'abord nécessaire de déterminer les critères utilisés pour définir la qualité d'un grain. D'autre part, la détection de chaque grain dans l'image est facilitée si l'on connaît le ou les types de forme que prennent les grains.

Une étape d'apprentissage de modèles de forme a donc été introduite pour permettre et faciliter la détection et la classification des objets dans une image où ceux-ci ne sont pas ordonnés. Cette étape est réalisée une seule fois pour une application donnée, avant toute détection. Les données recueillies lors de cet apprentissage de modèles de forme seront ensuite utilisées pour chaque analyse d'un lot de la même application.

Cette étape a pour but de caractériser les objets étudiés, on cherche notamment à définir les attributs qui leurs sont propres. Ces attributs seront utilisés ultérieurement en tant que paramètre des outils mis en place pour la détection. On distingue principalement deux intérêts majeurs à cette étape :

- déterminer une ou plusieurs forme(s) générique(s), représentative(s) de la nature géométrique des objets étudiés qui seront utilisées durant l'étape de détection ;
- définir les critères qui caractérisent les objets, ces données seront utilisés lors de la classification ainsi que lors de l'étape de détection pour vérifier que l'objet détecté répond aux critères de recherche et ainsi éviter de fausse détection.




FIGURE 3.1 – Images de grains isolés utilisées pour l’apprentissage de modèles de forme.

L’apprentissage de modèles de forme est réalisé sur une image d’objets isolés. Un opérateur dispose les objets sur le plateau de l’instrument, de manière à ce qu’ils ne se touchent pas et qu’il n’y ait ainsi aucun contact, comme sur la figure 3.4a.

La première section de ce chapitre traite de l’extraction des objets dans les images destinées à l’apprentissage de modèles de forme, plus particulièrement de la séparation entre les objets et le fond (3.1). La seconde section présente les attributs sélectionnés pour caractériser les objets étudiés (3.2), ils sont de nature différente : attributs géométriques, moments de Hu, descripteurs de Fourier. La troisième section présente les méthodes mises en place pour obtenir et modéliser des objets représentatifs des grains étudiés (3.3), qui seront utilisés pour traiter la détection. Enfin, des résultats d’apprentissage de modèles de forme sont présentés dans la dernière section (3.4).

3.1 Séparation objets-fond

La première étape consiste à déterminer une méthode pour distinguer les objets et le plateau. Le système d’acquisition, présenté dans le chapitre précédent (2), a été conçu pour offrir des conditions d’acquisition stables et reproductibles. Dans ce contexte, nous avons mis au point une méthode de séparation des objets et du fond par apprentissage préalable d’une image de fond seul, sans objet. Cette image est ensuite utilisée lors de l’acquisition d’images avec objets pour être soustraite et ainsi réaliser la séparation entre le fond et les objets. Cette approche a été adaptée à de nombreuses applications s’adaptant à différents contextes [4]. Cette étape peut être également être dans certains cas traitée en utilisant l’approche d’Otsu [41]. La méthode d’Otsu est alors utilisée sur l’histogramme du canal valeur du modèle TSV de l’image (Teinte Saturation Valeur, ou HSV pour Hue Saturation Value en anglais).

La figure 3.2 présente des résultats de séparation entre fond et objets, obtenus en utilisant la méthode basée sur la soustraction du fond préalablement appris, en considérant un ensemble d’objets varié et des grains de blé. La figure 3.3 présente un agrandissement des résultats. La figure 3.4 présente une séparation des objets et du fond réalisée en utilisant la méthode d’Otsu sur une image en niveaux de gris (canal valeur du modèle




FIGURE 3.2 – Image de fond seul (3.2a), image d’objets (3.2b, 3.2d) et image après séparation des objets et du fond (3.2c, 3.2e).

TSV.

3.2 Attributs/Paramètres

3.2.1 Attributs géométriques

Une fois la séparation entre les objets et le fond réalisée, l’image binaire est alors considérée pour obtenir les contours des objets par la méthode des composantes connexes de Suzuki [53]. Depuis cette image binaire et les contours associés, on extrait différents types d’informations pour chaque objet. De nombreux travaux sur la caractérisation d’objets de type grain [1, 25, 35, 36] nous ont permis de définir un ensemble d’informations à extraire durant cette étape. Tout d’abord, des informations relatives au positionnement telles que :

- les coordonnées du centre de l’objet ;
- son orientation : il s’agit de l’orientation de l’objet telle que décrit dans la section 3.2.3.

Un ensemble d’attributs géométriques est également obtenus pour chaque objet :

- aire : il s’agit de l’aire en pixels de l’objet, en considérant la ligne de contour comme appartenant à l’objet ;



FIGURE 3.3 – Image de fond seul, image d’objets et image après séparation des objets et du fond.




FIGURE 3.4 – Image de 100 grains de riz isolés (3.4a), image binaire avec objets et fond séparés par la méthode d’Otsu (3.4b).

- périmètre : la longueur du contour obtenu en considérant la somme des distances euclidiennes entre deux points successifs du contour ;
- circularité : le rapport entre 4π fois l’aire, divisé par le périmètre au carré ; cette mesure permet d’évaluer la nature circulaire d’un objet ;
- grand axe : il s’agit de la distance maximale entre deux points appartenant au contour ;
- petit axe : il s’agit de la distance entre deux points du contour qui forment la plus grande ligne perpendiculaire au grand axe ;
- moments de Hu : ces attributs sont détaillés dans la section 3.2.2 ;
- descripteurs de Fourier : la définition et la méthode sont présentées dans la section 3.2.3 ;
- transformée en distance : on extrait la valeur de la transformée en distance au centre de l’objet, plus de détails sont donnés dans la section 3.2.4.

Ces paramètres sont conservés dans un fichier associé à l'application, défini par l'utilisateur comme un modèle. Ils seront utilisés pour traiter la détection des objets. Des exemples portant sur les attributs extraits des images de la figure 3.1 sont présentés dans la table 3.1.

Riz, Figure 3.1 (a)					
Attributs	Aire	Grand axe	Petit axe	Périmètre	Circularité
Minimum	218	23	10	61	0.470
Maximum	559	51	15	114	0.840
Moyenne	422	43	13	96	0.576
Médiane	430	44	13	98	0.560
Écart type	64	6	1	10	0.067
Pois, Figure 3.1 (b)					
Attributs	Aire	Grand axe	Petit axe	Périmètre	Circularité
Minimum	894	35	29	115	0.601
Maximum	2061	55	48	176	0.927
Moyenne	1322	43	39	140	0.845
Médiane	1283	43	39	138	0.850
Écart type	233	4	3	12	0.045
Orge, Figure 3.1 (c)					
Attributs	Aire	Grand axe	Petit axe	Périmètre	Circularité
Minimum	842	61	16	149	0.309
Maximum	1812	101	24	253	0.528
Moyenne	1312	82	20	192	0.442
Médiane	1377	82	21	191	0.448
Écart type	266	11	2	25	0.045

TABLE 3.1 – Exemples de valeurs d'attributs obtenus durant l'apprentissage de modèles de forme.

3.2.2 Moments de Hu

Les moments de Hu sont également des paramètres pertinents pour caractériser une forme, ils sont fréquemment utilisés dans le domaine de la reconnaissance de forme. Pour une fonction 2D continue $f(x, y)$, le moment d'ordre $p + q$ est défini par :

$$m_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^p y^q f(x, y) \, dx \, dy \quad (3.1)$$

pour $(p, q) \in \{0, 1, 2, \dots\}^2$.

Hu a établi [28] que si $f(x, y)$ est continue par morceaux et non négative seulement sur un intervalle fini du plan xy , alors les moments de tout ordre existent. Les moments centrés sont invariant en translation, ils sont définis par :

$$\mu_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \bar{x})^p (y - \bar{y})^q f(x, y) \, dx \, dy \quad (3.2)$$

avec $\bar{x} = \frac{m_{10}}{m_{00}}$ et $\bar{y} = \frac{m_{01}}{m_{00}}$ les coordonnées du barycentre.

Il est alors possible de définir des moments invariant en translation, changement d'échelle et rotation. Ces moments sont obtenus en normalisant les moments centrés :

$$\eta_{ij} = \frac{\mu_{ij}}{\mu_{00}^{(1+\frac{i+j}{2})}} \quad (3.3)$$

Les moments définis par Hu [28] sont largement utilisés en reconnaissance de forme. Ces moments sont définis de la manière suivante :

$$\begin{aligned} H_1 &= \eta_{20} + \eta_{02} \\ H_2 &= (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2 \\ H_3 &= (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \\ H_4 &= (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2 \\ H_5 &= (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\ &\quad + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\ H_6 &= (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \\ H_7 &= (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\ &\quad - (\eta_{30} - 3\eta_{12})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \end{aligned} \quad (3.4)$$

Les moments de Hu permettent la distinction entre différentes formes. Les 6 formes artificielles présentées sur la figure 3.5) ont été utilisées pour obtenir les résultats contenus dans la table 3.2. On distingue sur la première ligne trois formes différentes : une première étoile (ET1), un éclair (EC), puis une seconde étoile (ET2). La première étoile (ET1) a été utilisée pour créer les formes de la seconde ligne, par changement d'échelle (ET1_S), par rotation (ET1_R), par changement d'échelle et rotation (ET1_{RS}).

Les valeurs obtenues par le calcul des moments de Hu (table 3.2) mettent en évidence leur capacité à distinguer ou rapprocher les différents types de formes. Les valeurs obtenues pour la forme ET1 sont sensiblement identiques à celles obtenues pour les formes obtenues par transformation de celle-ci (ET1_S, ET1_R et ET1_{RS}). On vérifie ici l'invariance de ces moments en translation, changement d'échelle et rotation. D'autre part, les valeurs des moments de Hu obtenues pour les trois formes de la première ligne (ET1, EC et ET2) permettent d'établir une proximité entre les deux formes de type étoile, par rapport à la forme type éclair qui leur est plus éloignée.

Forme	H_1	H_2	H_3	H_4	H_5	H_6	H_7
ET1	2.18×10^{-1}	1.04×10^{-4}	3.81×10^{-7}	2.64×10^{-8}	-1.50×10^{-15}	2.20×10^{-10}	-2.18×10^{-15}
EC	3.54×10^{-1}	8.63×10^{-2}	1.09×10^{-3}	6.78×10^{-4}	5.82×10^{-7}	1.98×10^{-4}	2.88×10^{-8}
ET2	1.96×10^{-1}	3.96×10^{-5}	1.88×10^{-4}	1.14×10^{-6}	-9.90×10^{-13}	-1.63×10^{-9}	1.66×10^{-11}
ET1 _S	2.18×10^{-1}	1.09×10^{-4}	1.71×10^{-7}	8.14×10^{-9}	7.20×10^{-17}	-1.22×10^{-11}	-2.95×10^{-16}
ET1 _R	2.19×10^{-1}	1.15×10^{-4}	5.19×10^{-7}	6.13×10^{-8}	9.34×10^{-15}	5.12×10^{-10}	5.65×10^{-15}
ET1 _{RS}	2.18×10^{-1}	1.19×10^{-4}	4.19×10^{-7}	2.69×10^{-8}	2.85×10^{-15}	-2.81×10^{-10}	1.22×10^{-17}

TABLE 3.2 – Valeurs des moments de Hu obtenues depuis les 6 formes de la figure 3.5.



FIGURE 3.5 – 6 formes artificielles avec de gauche à droite : étoile 1 (ET1), éclair (EC) et étoile 2 (ET2) sur la première ligne ; étoile 1 avec changement d'échelle (ET1_S), étoile 1 avec rotation (ET1_R) et étoile 1 avec changement d'échelle et rotation (ET1_{RS}) sur la seconde ligne.

3.2.3 Descripteurs de Fourier

Les descripteurs de Fourier ont été introduits par Zahn et Roskies [63] en 1972. Ces descripteurs peuvent être utilisés pour extraire des informations pertinentes sur des contours fermés dans le plan, mais également pour réaliser certaines transformations sur ces contours. Dans cette section, nous allons nous donc nous intéresser à ces propriétés, en se référant aux travaux de Folkers [21].

On considère un contour composé de N points successifs. Pour tout $n \in N$, on note $\mathbf{x}(n) = (x(n), y(n))$ le n -ième point du contour, $x(n)$ et $y(n)$ ses coordonnées dans l'image. On définit alors une fonction complexe discrète $u(n)$ telle que :

$$u(n) = x(n) + jy(n); \quad (3.5)$$

avec j l'unité imaginaire telle que $j^2 = -1$.

On peut alors obtenir la transformée de cette fonction dans le domaine fréquentiel en utilisant la transformation de Fourier discrète (TFD, ou DFT en anglais pour Discrete Fourier Transformation). La transformation inverse permettant de passer du domaine fréquentiel au domaine spatial est la transformation de Fourier discrète inverse (TDFI, ou IDFT en anglais pour Inverse Discrete Fourier Transformation). Ces transformations réalisées sans changement sur la fonction dans le domaine fréquentiel sont sans perte. La transformation de Fourier discrète $a(k)$ est définie pour $k = -N/2, \dots, N/2 - 1$ telle que :

$$a(k) = \frac{1}{N} \sum_{n=0}^{N-1} u(n) e^{-j2\pi kn/N}; \quad (3.6)$$

et son inverse $u(k)$ est défini pour $n = -N/2, \dots, N/2 - 1$ tel que :

$$u(n) = \sum_{k=0}^{N-1} a(k) e^{j2\pi kn/N}. \quad (3.7)$$

Les coefficients $a(k)$ sont appelés descripteurs de Fourier [29]. Un des intérêts de ces descripteurs est que certaines transformations géométriques dans le domaine spatial sont équivalentes à des opérations simples dans le domaine fréquentiel, on peut notamment noter parmi les propriétés remarquables :

- une translation du contour n’affecte que le premier descripteur de Fourier $a(0)$;
- un changement d’échelle du contour (agrandissement ou réduction) de coefficient α revient à multiplier tous les descripteurs de Fourier par α ;
- une rotation du contour d’un angle ϕ_0 se traduit par un décalage constant de phase d’angle ϕ_0 des descripteurs de Fourier ;
- un changement de point de départ du contour de valeur n_0 résulte en un décalage linéaire de phase de $2\pi n_0 k/N$ des descripteurs de Fourier.

Les descripteurs de Fourier sont finalement rendus invariants en rotation, translation et au changement d’échelle par normalisation.

On notera enfin que les descripteurs de Fourier permettent d’obtenir l’orientation ϕ_c d’un contour de manière rapide, à π radians près, en considérant les descripteurs $a(1)$ et $a(-1)$ de ce contour :

$$a(1) = r_1 e^{j\phi_1}; a(-1) = r_{-1} e^{j\phi_{-1}}; \quad (3.8)$$

on a alors :

$$\phi_c = \frac{\phi_1 + \phi_{-1}}{2}. \quad (3.9)$$

Une autre propriété intéressante dans le cadre de notre problématique concerne la reconstruction du contour. Le nombre de descripteurs retenus pour la reconstruction entraîne une approximation du contour plus ou moins proche de l’original. En considérant l’intégralité des descripteurs, on obtient le contour exact, mais en diminuant le nombre de descripteurs, le contour devient plus approximatif. Si l’on considère uniquement les descripteurs $a(1)$ et $a(-1)$, on obtient alors une ellipse modélisant le contour. Des exemples sont présentés dans la section 3.3.2.

La figure 3.7 présente des valeurs de descripteurs de Fourier obtenus en considérant le contour de l’objet présenté en figure 3.6. La taille de ce contour est de 2321 pixels. Depuis ce contour, comme décrit ci-dessus, les coordonnées $x(n)$ et $y(n)$ (figure 3.7) sont associées respectivement à la partie réelle et à la partie imaginaire d’une fonction complexe discrète. Pour plus de lisibilité, les coordonnées ont été centrées par rapport au centre de l’objet. Depuis cette fonction, on obtient les descripteurs de Fourier dont les parties réelles et imaginaires sont présentées sur la figure 3.7, centrées autour des valeurs réelles et imaginaires du descripteur $a(0)$. Il apparaît sur cette représentation



FIGURE 3.6 – Image artificielle d'un objet dont les descripteurs de Fourier sont présentés en figure 3.7.

que l'information est essentiellement regroupé autour de la valeur du descripteur $a(0)$, illustrant ainsi l'intérêt de ne pas considérer l'ensemble des descripteurs de Fourier pour approximer une forme.




FIGURE 3.7 – Haut : coordonnées du contour de l'objet présenté en figure 3.6 ; bas : descripteurs de Fourier associés au contour.

3.2.4 Transformée en distance

La transformée en distance, introduite par Borgefors [5], est un outil de morphologie mathématique. Depuis une image binaire, elle permet d'obtenir une carte de distance

contenant des informations qui se sont avérées pertinentes pour la détection d'objets en amas. Durant l'apprentissage de modèles de forme, nous cherchons à obtenir les valeurs obtenues par la transformée en distance aux centres des objets. La moyenne et l'écart type sur ces valeurs sont ensuite calculés et enregistrés pour être exploité pendant la détection. La méthode utilisée pour calculer la carte de transformée en distance est celle décrite par Meijster et al. [37], utilisant la distance euclidienne et un voisinage 8. Les détails de l'utilisation de ces valeurs durant la détection sont présentés dans le chapitre 4.

La figure 3.9 présente une image obtenue en appliquant la transformée en distance euclidienne avec un voisinage de 8 depuis l'image binaire de la figure 3.8 sur laquelle objets et fond ont été préalablement séparés. Depuis l'image de la figure 3.9, les valeurs de la transformée en distance sont extraites pour tous les objets en leur centre. La figure 3.10 présente des zooms sur 6 objets avec un repère placé autour de la valeur extraite ; les valeurs extraites correspondantes sont contenues dans la table 3.3.




FIGURE 3.8 – Image d'apprentissage de modèles de forme binarisée : 100 grains de blé sont séparés du fond.




FIGURE 3.9 – Image de transformée en distance euclidienne avec un voisinage 8.

Objet	Valeur de transformée en distance au centre
Figure 3.10a	9.2
Figure 3.10b	9.9
Figure 3.10c	7.0
Figure 3.10d	11.3
Figure 3.10e	10
Figure 3.10f	8

TABLE 3.3 – Exemples de valeurs de transformée en distance obtenues durant l'apprentissage de modèles de forme.




FIGURE 3.10 – Zooms sur 6 objets de l’image de transformée en distance avec en bleu le repère autour du centre de l’objet.

3.3 Protocoles envisagés

Le but de l’apprentissage de modèles de forme est, d’une part, d’extraire des informations pertinentes sur les objets tels que des attributs, des moments ou des descripteurs, et d’autre part, de définir une ou plusieurs formes modèles sur lesquelles sera basée la détection. Cette étape de définition de modèles est réalisée depuis l’image d’objets isolés représentatifs de l’ensemble des types de grains qui seront présentés en vrac a posteriori. Pour une application donnée, la forme des grains est relativement générique, même si il existe des variations de tailles et de formes. On peut ainsi distinguer des petits et des grands grains ou encore des grains cassés. D’autre part, la mise en place des objets est réalisée manuellement par un opérateur, des erreurs de placement peuvent éventuellement être observées, entraînant des contacts entre les objets.

Il existe différentes méthodes pour appréhender la modélisation de formes modèles depuis une image d’objets isolés. Une approche classique consiste à établir des classes d’objets en fonction de critères tels que leurs attributs géométriques (aire, périmètre, circularité, ...). La méthode des k-means permet par exemple d’établir une classification des objets en fonction de tels critères. Cependant, le nombre de classes ne peut pas être

déterminé directement. En effet, comme nous l'avons mentionné précédemment, la mise en place manuelle des objets par un opérateur peut introduire des erreurs. D'autre part, la sélection des critères pour établir des classes pertinentes vis à vis de l'application visée peut varier selon cette application même.

Dans le but d'automatiser au maximum cette étape d'apprentissage de modèles de forme, nous nous sommes donc orientés vers une méthode appelée forme moyenne, qui présente les intérêts de ne pas nécessiter de sélection de critères et de pouvoir traiter d'éventuels objets collés tout en tenant compte des différents types de formes. Cette approche est présentée dans la section 3.3.1. La forme moyenne obtenue doit ensuite être modélisée pour être utilisée lors de la détection. Différentes approches ont été mises au point : modélisation par une ellipse, par une superellipse ou par les descripteurs de Fourier. Ces approches sont détaillées dans la section 3.3.2.

3.3.1 Forme moyenne

Dans le but de créer une ou plusieurs forme(s) modèle(s) qui seront utilisées lors de l'étape de détection des objets, nous avons mis au point une approche basée sur la notion de forme moyenne (mean shape en anglais).

Pour chaque objet isolé détecté de l'image d'apprentissage de modèles de forme, le contour de celui-ci est extrait. Dans un premier temps, l'ensemble des attributs présentés dans la section 3.2.1 sont calculés. L'orientation de l'objet est alors modifiée de manière à aligner l'objet horizontalement selon son grand axe. La rotation est effectuée dans le domaine fréquentiel pour limiter les problèmes d'interpolation qui peuvent être rencontrés en procédant à une rotation classique. L'angle de cette rotation est obtenu grâce aux descripteurs de Fourier, à π radians près. La figure 3.11 illustre ce redressement de l'objet.




FIGURE 3.11 – Redressement d'un objet depuis l'information d'orientation obtenue par les descripteurs de Fourier .

On génère ensuite 3 images en appliquant trois transformations à l'image de l'objet redressé : symétrie verticale, symétrie horizontale et symétrie centrale. Enfin ces 4 images sont sommées puis le résultat est normalisé pour obtenir une image moyenne de l'objet dont les valeurs sont comprises entre 0 et 1. La figure 3.12 illustre ce processus.

L'image moyenne de l'objet est ajoutée à l'image de forme moyenne. Dès lors que tous les objets ont été parcourus et ajoutés à l'image de forme moyenne, on divise l'en-



FIGURE 3.12 – Processus de construction de l'image moyenne de l'objet.

semble des pixels de cette image par le nombre d'objets : l'image de forme moyenne est normalisée, ses valeurs sont donc comprises entre 0 et 1. Des exemples d'images de forme moyenne sont présentées en figures 3.19, 3.20 et 3.21, avec une échelle comprise en 0 et 255 visuellement mieux adaptée.

Depuis l'image de forme moyenne, nous souhaitons obtenir des modèles de forme représentatifs des objets contenus dans l'image qui a été utilisée. Les valeurs de l'image de forme moyenne sont quantifiées sur 10 niveaux. On étudie ensuite la répartition de chacun des objets par rapport à ces niveaux : on établit donc un histogramme de la répartition des objets le long de la forme moyenne. La totalité des objets parcourus, on recherche les maxima locaux de cette répartition : les courbes de niveaux de l'image moyenne correspondantes aux maxima locaux sont alors retenues comme modèles de forme. La figure 3.13 illustre cette étape : depuis une forme moyenne obtenue pour des grains d'orge (3.13a), un histogramme de répartition des grains le long de cette forme moyenne est calculé (3.13b) pour finalement obtenir deux modèles de formes (3.13c) depuis les maxima locaux identifiés. Nous avons également laissé la possibilité à l'utilisateur de définir lui même les niveaux qu'ils souhaitent sélectionner. A cette étape, les modèles de forme sont donc obtenus, mais il reste à les modéliser.




FIGURE 3.13 – Forme moyenne obtenue pour des grains d'orge (3.13a), histogramme de la répartition des grains sur cette forme (3.13b) et modèles de forme obtenus en considérant les maxima locaux de l'histogramme (3.13c).

3.3.2 Modélisation d'une forme moyenne

Depuis l'image de forme moyenne, plusieurs méthodes ont été explorées pour représenter la ou les forme(s) utilisée(s) lors de l'étape de détection. Cette modélisation doit permettre de manipuler la forme sans engendrer un coût de calcul trop important. Nous avons tout d'abord considéré une forme géométrique simple : l'ellipse. Cette forme facilement paramétrable est en effet une approximation satisfaisante d'un certain nombre de grains. Cependant, elle n'est pas adaptée à tous les grains, et particulièrement les grains présentant des formes allongées avec des extrémités pointues. Nous nous sommes alors tournés vers l'utilisation de superellipses pour palier ce manquement. Les superellipses, aussi connues sous le nom de courbes de Lamé, demeurent une forme géométrique simple (trois paramètres : grand axe, petit axe et puissance). Dans l'optique de généraliser les formes d'objets que nous pourrions traiter, les descripteurs de Fourier sont apparus pertinents. Cependant, les paramètres d'une ellipse ou d'une superellipse sont plus faciles à interpréter pour l'utilisateur, contrairement aux descripteurs de Fourier.

Ellipse

La modélisation de modèles de forme par une ou plusieurs ellipses a été réalisée en utilisant la fonction *fitEllipse* de la librairie OpenCV [40]. Cette fonction permet d'approximer la forme d'un contour par une ellipse. Cette approximation est basée sur la méthode de Fitzgibbon et Fisher [20]. Des exemples de modélisation par ellipses sont présentées en figures 3.19, 3.20 et 3.21.

Superellipse

La superellipse est une forme géométrique dont l'utilisation est moins répandue que l'ellipse. Cependant, elle semble adaptée à la forme de nombreux grains de céréales. Nous nous sommes donc intéressés au moyen d'approximer une forme par une superellipse. L'équation d'une superellipse, aussi connue sous le nom de courbe de Lamé, est définie telle que :

$$\left(\frac{x}{a}\right)^\epsilon + \left(\frac{y}{b}\right)^\epsilon = 1 \quad (3.10)$$

avec (a, b) les demis axes de la superellipse et ϵ un nombre positif. La paramétrisation de cette forme géométrique est relativement simple, puisque elle est définie en fonction de seulement trois paramètres, tout en offrant une variété de formes intéressante. La notion de superellipse a été notamment utilisée en infographie [2] et vision par ordinateur [43]. La figure 3.14 présente 8 superellipses obtenues en faisant varier uniquement le paramètre ϵ . On remarquera que la superellipse obtenue avec ϵ égal à 2 est bien une ellipse.

L'inconvénient de cette forme est la nature non linéaire de ϵ , il est nécessaire d'utiliser des méthodes itératives pour réaliser l'approximation. Cette approximation consiste alors à estimer les paramètres depuis les données fournies. La méthode la plus courante est celle des moindres carrés [52, 62]. Nous nous sommes en particulier intéressés aux derniers travaux sur le sujet [50, 51, 64]. La méthode présentée ici est celle décrite par Zhang et Rosin [64].




FIGURE 3.14 – 8 superellipses obtenues en faisant varier la valeur du paramètre ϵ (de gauche à droite et de haut en bas) : 0.25, 0.6, 0.9, 1.3, 1.6, 2, 2.3, 2.65.

On note $\rho = \frac{2}{\epsilon}$ et on définit la distance algébrique $Q_0(x, y)$ telle que :

$$Q_0(x, y) = \left(\frac{(x - x_c) \cos(\theta) - (y - y_c) \sin(\theta)}{a} \right)^{\frac{2}{\rho}} + \left(\frac{(y - y_c) \cos(\theta) + (x - x_c) \sin(\theta)}{b} \right)^{\frac{2}{\rho}} - 1. \quad (3.11)$$

avec (x_c, y_c) les coordonnées du centre de la superellipse considérée et θ l'angle définissant son orientation. La meilleure approximation de superellipse est obtenue en déterminant le jeu de paramètres qui minimise la fonction objectif $Q_0(x, y)$.

Pour simplifier l'expression cette étape, Zhang et Rosin définissent la transformation $T(x_c, y_c, a, b, \theta, \rho)$ depuis l'espace d'origine $\{x, y\}$ vers un nouvel espace $\{X, Y\}$:

$$\begin{cases} X = \left(\frac{(x - x_c) \cos(\theta) - (y - y_c) \sin(\theta)}{a} \right)^{\frac{1}{\rho}}, \\ Y = \left(\frac{(y - y_c) \cos(\theta) + (x - x_c) \sin(\theta)}{b} \right)^{\frac{1}{\rho}} \end{cases} \quad (3.12)$$

L'équivalence suivante peut alors être établie :

$$Q'_0(X, Y) = X^2 + Y^2 - 1 = Q_0(x, y) \quad (3.13)$$

Le problème initial a ainsi été ramené à une approximation par un cercle dans le domaine XY . Zhang et Rosin étendent alors le principe de distance algébrique pour ajouter une mesure de la forme de la courbe (gradient, courbure,...). Pour cela, ils s'intéressent d'abord au cercle unité dans l'espace $\{X, Y\}$. Pour tout point $(U, V) = (\cos(t), \sin(t))$

situé sur le cercle unité, on a : $U^2 + V^2 = 1$. En dérivant cette dernière équation par rapport à t , on obtient l'équation : $2UU'_t + 2VV'_t = 0$. Depuis l'égalité $(U'_t)^2 + (V'_t)^2 = 1$ et en dérivant une nouvelle fois, on obtient $UU''_t + VV''_t + 1 = 0$.

On pose alors $Q_1(x, y) = XX'_t + 2YY'_t$ et $Q_2(x, y) = XX''_t + YY''_t + 1$. Pour tout point (u, v) situé sur la superellipse on a alors : $Q_0(u, v) = Q_1(u, v) = Q_2(u, v) = 0$. Zhang et Rosin définissent alors une nouvelle fonction objectif dans le domaine XY , intégrant une combinaison linéaire des termes Q_1 et Q_2 , qu'ils notent $F(x, y)$:

$$F(x, y) = (1 - w_1 - w_2)Q_0^2(x, y) + w_1Q_1^2(x, y) + w_2Q_2^2(x, y), \quad (3.14)$$

avec $w_1, w_2 \leq 0$ et $w_1 + w_2 \geq 1$. L'approximation par superellipse consiste alors à minimiser $F(x, y)$, ce qui revient à minimiser simultanément $Q_0^2(x, y)$, $Q_1^2(x, y)$ et $Q_2^2(x, y)$. Cette fonction objectif ainsi définie permet de mesurer la qualité de l'approximation d'une courbe par une superellipse.

Pour déterminer le jeu de paramètres qui fournit la meilleure approximation, F est exprimée en fonction de six inconnus : x_c, y_c, a, b, θ et ρ . La fonction objectif est alors notée $F(x_c, y_c, a, b, \theta, \rho)$, elle est non linéaire. L'algorithme itératif de Levenberg-Marquardt [47] est alors utilisé pour minimiser cette fonction objectif.




FIGURE 3.15 – Modélisations par des ellipses (haut) et des superellipses (bas) de grains de riz (gauche) et d'orge de type 1 (milieu) et 2 (droite).

Des exemples d'approximation par superellipses sont présentés sur les figures 3.19,

3.20 et 3.21. La figure 3.15 présente des modélisations par ellipses et par superellipses sur différents type de grains. Par rapport à l'ellipse, la superellipse apporte effectivement une modélisation plus précise du contour des grains ayant des extrémités plus pointues, comme l'orge de type 1, ou une forme se rapprochant de celle d'un losange, comme l'orge de type 2.

Descripteurs de Fourier

Les descripteurs de Fourier permettent également la modélisation de modèles de forme [36]. Comme décrit dans la section précédente 3.2.3, le nombre de descripteurs de Fourier associés à un contour est proportionnel au nombre de points qui le constituent. En outre, le nombre de descripteurs retenus pour la reconstruction d'un contour conditionne la qualité de l'approximation du contour : si l'on considère la totalité des descripteurs, on obtient le contour exact (figure 3.17a) ; mais à mesure qu'on diminue le nombre de descripteurs, on fait une approximation de plus en plus grossière du contour lors de la reconstruction jusqu'à obtenir une ellipse (figure 3.17h). C'est pourquoi nous avons choisi de ne conserver qu'un pourcentage jugé significatif de ces descripteurs, proportionnel à la taille du contour initial. Il a été établi de manière empirique de conserver un nombre de descripteurs de Fourier égal à 10% du nombre de points qui constitue le contour considéré, cela permet d'obtenir une approximation des contours fidèles tout en manipulant un nombre acceptable de variables.




FIGURE 3.16 – Zoom sur un objet depuis image originale (3.16a) et image en niveaux de gris de l'objet extrait par séparation avec le fond (3.16b).

Un exemple d'approximation d'un objet par les descripteurs de Fourier est donné : la figure 3.17 permet de constater l'influence du nombre de descripteurs de Fourier utilisés pour modéliser le contour d'un objet présenté en figure 3.16. Le contour de l'objet extrait après séparation avec le fond est constitué de 135 points. La modélisation retenue est donc celle qui considère 14 descripteurs de Fourier (figure 3.17e).

À l'issue de l'étape d'apprentissage de modèles de forme, un certain nombre de données sont conservées pour être exploitées lors de la détection. Cette étape est réalisée une fois, en s'appuyant sur une image d'objets isolés qui doivent être représentatifs des différents types de grains de l'application. Elle permet d'extraire des données sur les ob-




FIGURE 3.17 – Image binaire obtenue par reconstruction d’un contour en faisant varier le nombre de descripteurs de Fourier utilisés (table 3.4).

jets : attributs, moments, descripteurs ; mais également de définir des modèles de forme nécessaires à l’étape de détection détaillée dans le chapitre 4. La synthèse des différentes étapes qui composent l’apprentissage de modèles de forme est présentée sous forme de diagramme en figure 3.18.

3.4 Résultats d’apprentissage de modèles de forme

Les figures 3.19, 3.20 et 3.20 présentent des résultats obtenus à l’issue de l’étape d’apprentissage de modèles de formes, respectivement pour des grains de blé, d’orge de type 1 et d’orge de type 2.

Pour chaque type de grains, les figures 3.19, 3.20 et 3.20 présentent la forme moyenne obtenue (figures 3.19a, 3.20a et 3.21a), puis les différentes modélisations qui en ont été faites en considérant les maxima locaux de la répartition des objets le long de la forme moyenne :

- ellipses :
 - blé : figures 3.19b, 3.19c et 3.19d ;
 - orge de type 1 : figures 3.20b, 3.20c et 3.20d ;
 - orge de type 2 : figures 3.21b, 3.21c et 3.21d ;
- superellipses :

Figure	Nombre de descripteurs utilisés pour la reconstruction
3.17a	70
3.17b	46
3.17c	22
3.17d	18
3.17e	14
3.17f	8
3.17g	4
3.17h	2

TABLE 3.4 – Nombres de descripteurs de Fourier utilisés pour obtenir les reconstructions présentées en figure 3.17.

- blé : figures 3.19e, 3.19f et 3.19g ;
- orge de type 1 : figures 3.20e, 3.20f et 3.20g ;
- orge de type 2 : figures 3.21e, 3.21f et 3.21g ;
- descripteurs de Fourier :
 - blé : figures 3.19h, 3.19i et 3.19j ;
 - orge de type 1 : figures 3.20h, 3.20i et 3.20j ;
 - orge de type 2 : figures 3.21h, 3.21i et 3.21j.

Ces résultats permettent de constater qu’il n’y a pas de modélisation privilégiée, chaque grain ayant sa forme propre. Pour les grains de blé (figure 3.19), la modélisation par une ellipse est parfaitement adaptée, la superellipse et les descripteurs de Fourier n’apportent pas d’avantage, il y a donc tout intérêt à considérer cette modélisation qui est la plus simple, celle qui comporte le moins de paramètres.

Pour modéliser les grains d’orge de type 1 (figure 3.20), la superellipse apparaît être la forme la plus adaptée. La spécificité de ces grains provient de leur extrémités horizontales pointues, l’ellipse ne peut pas modéliser correctement cet aspect, et les descripteurs de Fourier ne le permettraient que s’ils étaient conservés entièrement, ce qui engendrerait un nombre de paramètres trop importants à manipuler. La superellipse est donc la forme retenue pour ce type de grains.

La modélisation des grains d’orge de type 2 (figure 3.21) est assez délicate, la forme de ces grains est semblable à celle d’un losange dont les extrémités auraient été rognées. L’ellipse ne permet pas une modélisation précise pour ce type de grain, et la superellipse n’autorise pas une forme avec de telle extrémités. Les descripteurs de Fourier sont bien adaptés à la modélisation de ce type de grains.

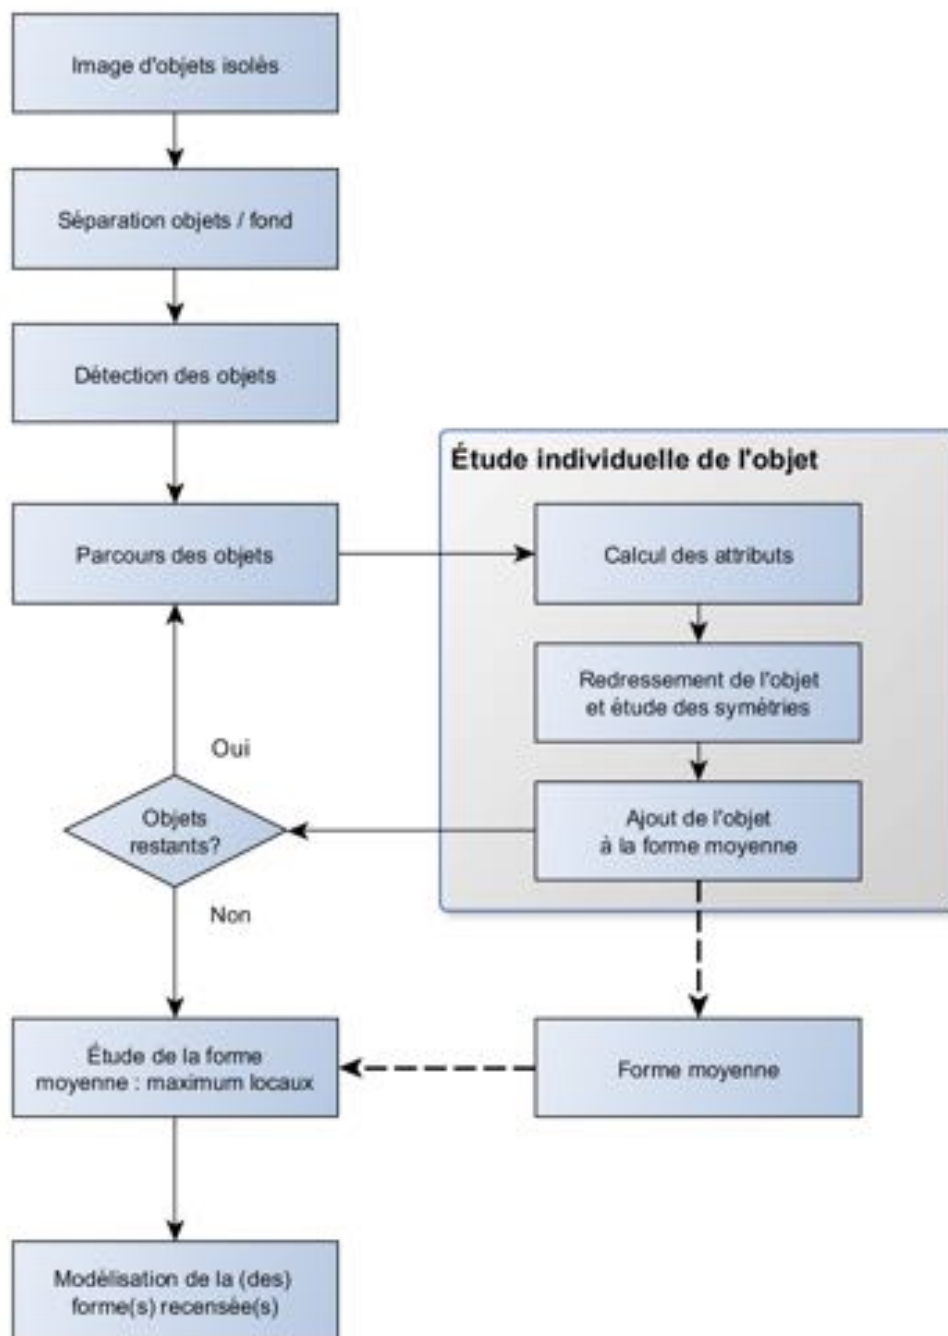


FIGURE 3.18 – Schéma des différentes étapes de l'apprentissage de modèles de forme depuis une image d'objets isolés.




FIGURE 3.19 – Image de forme moyenne obtenue sur des grains de blé 3.19a et modèles de forme obtenus : 3 formes ont été modélisées par des ellipses (3.19b, 3.19c et 3.19d), des superellipses (3.19e, 3.19f et 3.19g) et les descripteurs de Fourier (3.19h, 3.19i et 3.19j).




FIGURE 3.20 – Image de forme moyenne obtenue sur des grains d’orge de type 1 3.20a et modèles de forme obtenus : 3 formes ont été modélisées par des ellipses (3.20b, 3.20c et 3.20d), des superellipses (3.20e, 3.20f et 3.20g) et les descripteurs de Fourier (3.20h, 3.20i et 3.20j).




FIGURE 3.21 – Image de forme moyenne obtenue sur des grains d’orge de type 2 3.21a et modèles de forme obtenus : 3 formes ont été modélisées par des ellipses (3.21b, 3.21c et 3.21d), des superellipses (3.21e, 3.21f et 3.21g) et les descripteurs de Fourier (3.21h, 3.21i et 3.21j).

Chapitre 4

Détection

Ce chapitre traite la problématique de détection d’objets présentés en vrac. Cette étape consiste à déterminer la position et la forme des objets dans l’image en exploitant les informations extraites lors de l’étape d’apprentissage de modèles de forme. Un état de l’art de différents travaux portant sur ce sujet est présenté dans la première section 4.1. La seconde section 4.2 présente les différents outils mis en place pour traiter la détection : méthode de séparation des objets et du fond, indicateurs conçus depuis différentes informations utilisés pour former une énergie renseignant sur la position et l’orientation des objets, méthode de contour actif utilisée pour obtenir les contours des objets de façon plus précise, tenseur de structure permettant d’obtenir une information plus précise sur l’orientation d’un objet, méthode de validation des objets détectés. La section 4.3 présente deux approches différentes utilisant ces outils : une méthode déterministe et une méthode probabiliste. Les techniques utilisées pour évaluer la qualité de la détection sont détaillées dans la section 4.4. Enfin, des résultats de détection sont présentés dans la section 4.5.

4.1 État de l’art

La problématique de détection d’objets de type grains de céréale a récemment donné lieu à de nombreuses publications [19, 32, 57, 61, 65]. La majorité des travaux portent sur les céréales les plus échangées à travers le monde : le riz et le blé.

Yao et al. [61] et Faessel et al. [19] se sont intéressés à la détection et à la séparation de grains de riz. Ils ont tous les deux abordé le problème en travaillant sur une image binaire obtenue après seuillage des objets par rapport au fond, les frontières entre le fond et les objets sont en effet de premières informations solides qui renseignent partiellement sur la disposition des objets et constituent un point de départ intéressant. Yao et al. [61] traitent ensuite le problème en travaillant sur les contours et en recherchant les angles concaves qui sont ensuite reliés deux à deux pour former les frontières entre les objets collés.

Faessel et al. [19] utilisent une approche de morphologie mathématique sur l'image binaire, en appliquant une squelettisation sur le fond. Les lignes ouvertes du squelette, c'est-à-dire sans terminaison, sont alors jointes deux à deux, sous certaines conditions, de manière à construire les frontières des grains. Ces deux méthodes fournissent de bons résultats sur des images de faible densité de grains, avec des temps de calcul courts, mais ne sont pas adaptées aux images comportant des amas de grains ou des zones de haute densité.

Wang et Paliwal [57] se sont intéressés à la séparation et l'identification de grains de céréales (blé, orge, avoine). Leur approche est basée sur l'utilisation de la transformée en distance euclidienne. Cette transformation est appliquée sur une image binaire obtenue après prétraitement de l'image originale en niveaux de gris : objets et fond sont séparés en appliquant un seuillage dont les paramètres sont déterminés manuellement. La méthode de segmentation par ligne de partage des eaux est ensuite appliquée sur l'image de transformée en distance. La sur-segmentation, quasi-systématique, est corrigée en utilisant des marqueurs intérieurs et extérieurs aux objets, obtenus par des opérations de morphologie mathématique. Les contours des objets sont finalement obtenus après lissage des frontières corrigées par les marqueurs. L'approche fournit des résultats intéressants sur des images de haute densité de grains (plusieurs dizaines), présentés collés en amas. Cependant, l'utilisation d'une méthode telle que la ligne de partage des eaux a tendance à fournir des résultats sur-segmentés, malgré l'utilisation de marqueurs, particulièrement lorsque la forme des objets à détecter est allongée, comme celle de grains de riz ou d'orge de certaines variétés.

Zhong et al. [65] ont mis au point une méthode associant concavité et ligne de partage des eaux. Sous l'hypothèse que les grains à détecter sont de forme convexe, ils établissent qu'il existe au moins un point de concavité apparent entre deux grains qui se touchent. Depuis une image binaire distinguant objets et fond, une recherche des points de concavités est réalisée, ils sont localisés et leurs orientations sont calculées. Depuis l'image binaire également, une image en niveaux de gris est obtenue en appliquant la transformée en distance euclidienne. La méthode de la ligne de partage des eaux est alors appliquée sur cette image, fournissant là encore une sur-segmentation quasi systématique. Les sur-segmentations sont éliminées par une succession d'étapes basées sur la recherche de liens entre les frontières retournées par la ligne de partage de eaux et les positions et orientations des points de concavité précédemment calculés. Zhong et al. présentent des résultats obtenus sur des images contenant un grand nombre d'objets et de haute densité : de 50 à 1 000 grains de riz, de formes variées, plus ou moins allongées ou arrondies. Les erreurs de comptage, obtenues en comparant les résultats de la méthode avec ceux fournis par un opérateur humain, sont excellents : inférieurs à 0,5 % en moyenne. Cette approche permet donc le comptage précis des objets, même sur des images de haute densité d'objets. Néanmoins, les contours des objets ne sont pas précisément détectés, particulièrement pour les frontières inter objets qui sont rectilignes, car obtenus en reliant deux points distants de manière directe.

Lin et al. [32] proposent de traiter la séparation de grains de riz présentés en amas par une méthode intitulée "MCCPs" pour most convex or concave points, ils s'intéressent aux points appartenant à un contour et qui présentent les valeurs de convexité ou de concavité les plus importantes. La première étape consiste une nouvelle fois à séparer objets et fond. Les contours correspondants aux frontières entre objets et fond sont ensuite extraits puis lissés en appliquant un filtre gaussien 1D par convolution. Les contours lissés sont alors étudiés afin de déterminer les portions convexes et leurs centres de courbures. Les points extrêmes sont répertoriés et listés, puis considérés un à un afin de déterminer quel est le meilleur candidat parmi les autres dans la liste et ainsi définir une frontière formée en joignant ces deux points. Cette mise en correspondance de points est faite selon des critères bien définis, tels que la disposition des deux points testés (distance, orientation) ou encore la position du candidat par rapport au centre de courbure du point considéré. Lin et al. présentent des résultats obtenus par cette méthode sur des images de grains de riz en faible et haute densité, de 3 à plusieurs dizaines de grains. La détection est efficace en terme de comptage, la totalité des grains sont détectés sur les résultats présentés. Cependant, cette méthode ne permet pas non plus d'obtenir une information précise de la forme des objets : les frontières inter objets sont rectilignes, les points étant simplement reliés par une droite. Cette méthode fournit donc un comptage fiable des grains, mais elle ne permet pas d'extraire des informations précises sur ces grains telles que leurs tailles.

Ces travaux nous ont amenés à mettre au point une nouvelle méthode de détection d'objets de type grains de céréales, capable de traiter des images de faible à haute densité et de définir les contours des objets détectés de façon précise.

4.2 Outils

Différents outils ont été conçus pour traiter l'étape de détection. L'approche retenue pour séparer les objets du fond sur une image est tout d'abord présentée dans la section 4.2.1. Quatre indicateurs mis au point pour renseigner la position, la forme et l'orientation des objets sont ensuite présentés dans la section 4.2.2, puis l'énergie construite à partir des informations données par ces indicateurs est définie dans la section 4.2.3. Une méthode basée sur l'utilisation d'un tenseur de structure permettant d'obtenir une approximation précise de l'orientation des objets est détaillée dans la section 4.2.4. Une méthode de contour actif avec a priori de forme visant à obtenir non plus une approximation de la forme de l'objet mais son contour précis est ensuite présentée en section 4.2.5. Enfin, la méthode mise en place pour la validation des objets détectés est présentée dans la section 4.4.




FIGURE 4.1 – Exemples de séparation du fond et d’objets disposés en amas : orge (4.1a), riz (4.1b) et blé (4.1c).

4.2.1 Séparation objets/fonds

Comme nous l’avons vu dans le chapitre apprentissage de modèles de forme, la séparation entre les objets et le fond peut être réalisée par deux approches différentes selon l’application : par soustraction du fond, celui-ci ayant été préalablement appris, ou par la méthode d’Otsu lorsque les objets présentent des caractéristiques radiométriques fortement différentes du fond. Les deux méthodes permettent d’obtenir une image sur laquelle objets et fond sont séparés. La valeur attribuée aux pixels déterminés comme appartenant au fond est la valeur nulle 0, 0, 0. Les autres pixels sont considérés comme appartenant aux objets et conservent leurs valeurs. Sur la figure 4.1, des exemples de séparation du fond et d’objets disposés en amas sont présentés : grains d’orge (figure 4.1a), grains de riz (figure 4.1b) et grains de blé (figure 4.1c).

4.2.2 Indicateurs

Dans le but de segmenter les objets de type grains présentés en amas non ordonnés dans une image, quatre indicateurs ont été mis au point. Ces indicateurs sont calculés indépendamment dans un premier temps, puis assemblés sous la forme d’une énergie, définie dans la section 4.2.3. Cette énergie a pour but de renseigner sur la position, la forme et l’orientation des objets dans l’image. Deux méthodes de détection ont été développées, une première dite déterministe et une autre dite probabiliste. Ces deux approches sont basées sur l’utilisation de l’information fournie par cette énergie. Nous allons donc introduire et définir dans cette section les différents indicateurs avant de présenter comment est établie l’énergie depuis les indicateurs dans la section suivante.

Tout d’abord, on notera que chacun des indicateurs fournit une information comprise entre 0 et 1. On distingue l’indicateur I_4 des trois premiers indicateurs I_1 , I_2 et I_3 par le fait que celui-ci n’est pas calculé par rapport à un modèle de forme. A l’inverse, pour chaque modèle de forme issue de l’apprentissage, les indicateurs I_1 , I_2 et I_3 sont calculés à différentes orientations en tout point de l’image n’appartenant pas au fond. Le nombre d’orientations, autrement dit le pas, est un paramètre ; il ne doit pas être trop

important pour ne pas ralentir le calcul en introduisant un trop grand nombre de cas, mais il ne doit cependant pas être négligé au risque de perdre en précision et de ne plus être significatif.

La totalité des grains étudiés et présentés dans ce manuscrit présentent une forme relativement symétrique permettant de restreindre la rotation du modèle de forme à un intervalle compris entre 0 et 180 degrés. Ainsi, on économise du temps de calcul en divisant par deux les orientations possibles des modèles de forme.

Le but de la mise en œuvre de ces indicateurs et de l'énergie associée est de permettre la détection des objets. Pour cela, nous allons considérer les modèles de forme obtenus durant l'apprentissage et calculer les indicateurs en tout point de l'image qui n'appartient pas au fond, pour un nombre d'orientations de la forme modèle donnée. En chaque pixel considéré comme appartenant aux objets, nous calculons donc les quatre indicateurs à différentes orientations pour le nombre de modèles de forme définis durant l'apprentissage. Cela nous permet ensuite d'obtenir en chaque pixel objet de l'image les énergies associées aux formes modèles pour un nombre d'orientations donné.

Les notations utilisées pour définir les indicateurs sont les suivantes : Ω représente l'image, ω_θ la forme définie par l'objet modèle considéré, à une orientation donnée θ , $\partial\omega_\theta$ le contour de cette forme et $x \in \Omega$ une position dans l'image.




FIGURE 4.2 – De haut en bas : modèle de forme selon 5 pas d’orientations, zooms sur images de I_1 correspondantes, de I_2 et de I_3 . Ces données ont été obtenues depuis l’image présentée en figure 4.4

Matière

Le premier indicateur, noté I_1 , est relatif à la matière. Il est défini par :

$$I_1(\omega_\theta) = \frac{1}{\text{area}(\omega_\theta)} \int_{\omega_\theta} u_b(x) \, dx \quad (4.1)$$

avec area la fonction qui renseigne l’aire de la forme, u_b l’image binaire obtenue en considérant les valeurs des pixels égales à 1 si ils appartiennent aux objets, à 0 si ils appartiennent au fond. L’indicateur I_1 quantifie ainsi la matière que couvre la forme considérée, ce qui est nécessaire pour s’assurer qu’elle est bien située sur un objet, c’est-à-dire des pixels dont la valeur est différente de la valeur nulle attribuée au fond. Cet indicateur n’est cependant pas suffisant, il peut être mis en échec facilement dans les cas où des objets sont adjacents ou de taille supérieure à celle de la forme considérée.

La figure 4.2 présente des images de l'indicateur $1 - I_1$ à 5 orientations différentes pour un modèle de forme donné. Les valeurs sont comprises entre 0 (noir) et 1 (blanc). On peut souligner que ces valeurs de l'indicateur varient bien selon la position et l'orientation de la forme testée : les points où l'indicateur réagit le mieux sont bien obtenues à l'intérieur de la matière, et non sur des bords d'objets, et pour l'orientation la plus adaptée à la matière effective. Cette figure confirme également que cet indicateur n'est pas suffisant, il réagit également dans les zones denses de matières, là où se trouvent plusieurs grains.

Saut de gradient

Le deuxième indicateur, noté I_2 , est basé sur l'observation de sauts de gradient. Il est défini tel que :

$$I_2(\omega_\theta) = \frac{1}{\max_{y \in \Omega} (\|\nabla u(y)\|)} \frac{1}{|\partial\omega_\theta|} \int_{\partial\omega_\theta} \|\nabla u(x)\| \, dx \quad (4.2)$$

avec ∇u le gradient de l'image, $|\partial\omega_\theta|$ la longueur du contour de la forme et $\|\cdot\|$ la norme euclidienne.

La figure 4.2 présente des images de l'indicateur $1 - I_2$ à 5 orientations différentes pour un modèle de forme donné. Les valeurs sont comprises entre 0 (noir) et 1 (blanc). L'indicateur I_2 permet la position des centres de formes dont les contours sont situés sur des zones où le saut de gradient est important. Il réagit correctement sur les frontières entre les grains et le fond, qui sont fortement marquées, mais il ne permet pas la détection correcte de frontières entre deux grains, le saut de gradient étant moindre à cet endroit.

Normales au contour

Le troisième indicateur, noté I_3 , repose sur la notion de normales au contour. Il est défini de la manière suivante :

$$I_3(\omega_\theta) = \frac{1}{2|\partial\omega_\theta|} \int_{\partial\omega_\theta} \left\langle \frac{\nabla u(x)}{\sqrt{|\nabla u(x)|^2 + \epsilon^2}}, n(x) \right\rangle \, dx + \frac{1}{2} \quad (4.3)$$

avec $\langle \cdot, \cdot \rangle$ le produit scalaire euclidien, $n(x)$ la normale extérieure à ω à la position $x \in \partial\omega_\theta$ et ϵ un paramètre de régularisation.

La figure 4.2 présente des images de l'indicateur $1 - I_3$, à 5 orientations différentes pour un modèle de forme donné. Les valeurs sont comprises entre 0 (noir) et 1 (blanc). L'indicateur I_3 réagit pour les forts et faibles contrastes, mais peut également introduire de fausses réactions, sur des ombres ou des stries de grains par exemple.

Transformée en distance

Le quatrième et dernier indicateur est basé sur l'utilisation de la transformée en distance. Contrairement aux trois précédents indicateurs, la transformée en distance est indépendante de l'objet modèle. La valeur de cet indicateur dépend uniquement des

valeurs issues de l'apprentissage de modèles de forme. Lors de cet apprentissage, les valeurs de la transformée en distance aux centres des graines isolées sont extraites, puis utilisées pour obtenir la moyenne et l'écart type. Depuis ces valeurs, une loi de répartition est établie dans le but de favoriser les objets dont les valeurs de la transformée en distance au centre sont proches de la moyenne obtenue durant l'apprentissage de modèles de forme.




FIGURE 4.3 – Valeurs de sorties de l'indicateurs de transformée en distance en fonction des valeurs d'entrée, m représente la valeur moyenne et E l'écart type des valeurs relevées durant l'apprentissage de modèles de forme.

Cette loi de répartition, illustrée en figure 4.3, comprend cinq intervalles, elle est définie telle que :

— pour $V_{TD} \in [\overline{TD} - 3\Delta; \overline{TD} - 2\Delta]$:

$$i_4 = \frac{\overline{TD} - 2\Delta}{\Delta} - \frac{1}{\Delta}TD; \quad (4.4)$$

— pour $V_{TD} \in]\overline{TD} - 2\Delta; \overline{TD} + 2\Delta[$:

$$i_4 = 0; \quad (4.5)$$

— pour $V_{TD} \in [\overline{TD} + 2\Delta; \overline{TD} + 3\Delta]$:

$$i_4 = -\frac{\overline{TD} + 2\Delta}{\Delta} + \frac{1}{\Delta}TD; \quad (4.6)$$

— pour $V_{TD} < (\overline{TD} - 3\Delta)$ ou $V_{TD} > (\overline{TD} + 3\Delta)$:

$$i_4 = 1; \quad (4.7)$$

avec V_{TD} la valeur de la transformée en distance au point considéré, \overline{TD} la moyenne des valeurs de transformée en distance des objets considérés durant l'apprentissage de modèles de forme et Δ l'écart type associé.

La valeur de l'indicateur I_4 est alors définie telle que :

$$I_4 = 1 - e^{-i_d} + e^{-1}. \quad (4.8)$$

L'indicateur I_4 est ainsi défini entre 0 et 1, retournant des valeurs proches de 0 pour les valeurs de transformée en distance proches de la moyenne de celles obtenues aux centres des objets lors de l'apprentissage de modèles de forme. La figure 4.4 présente une image de l'indicateur I_4 ainsi que les images originale et binaire sur laquelle objets et fond sont séparés.




FIGURE 4.4 – Image de grains d'orge originale (gauche), image binaire séparant les objets du fond (milieu) et image de l'indicateur I_4 de transformée en distance.

4.2.3 Assemblage des indicateurs

Pour une forme modèle donnée ω , à une orientation donnée θ , les indicateurs sont calculés et ensuite assemblés sous la forme d'une énergie selon la formule suivante :

$$E(\omega_\theta) = \sqrt{(1 - I_1(\omega_\theta))^2 + (1 - I_2(\omega_\theta))^2 + (I_3(\omega_\theta))^2 + \gamma_4 I_4}. \quad (4.9)$$

avec γ_4 un paramètre de pondération permettant de régler l'influence de l'indicateur I_4 . Par défaut, cette valeur vaut 1, mais pour certains types de grains, il peut être utile d'adapter ce paramètre.

Les valeurs de cette énergie sont positives. Une carte d'énergie est obtenue pour chaque orientation θ de chaque forme modèle ω . Chaque carte d'énergie est une image en niveaux de gris qui associe en tout point une valeur dont le but est de qualifier l'éventuelle présence d'un objet, en considérant un modèle de forme avec une orientation donnée.

Une valeur proche de 0 permet d'établir que les indicateurs ont correctement réagi, et, qu'en d'autres termes, la présence d'un objet de forme similaire au modèle est probable en ce point à l'orientation considérée. L'assemblage des indicateurs sous la forme d'une

énergie a pour but de tirer partie des qualités de chaque indicateur, tout en minimisant leurs défauts.

Le calcul des trois premiers indicateurs est rapide : un filtre correspondant à l'opération considérée est créé. Ensuite, un produit de convolution de ce filtre avec l'image est réalisée. L'efficacité de cette approche vient du fait que le calcul du produit de convolution est réalisé par transformée de Fourier, rendant ainsi l'opération moins coûteuse en temps : la transformée de Fourier d'une convolution de deux fonctions est le produit des transformées de Fourier de ces deux fonctions.




FIGURE 4.5 – Carte des minimums de l'énergie E obtenue pour une image de grains de riz.

La figure 4.5 présente une carte des minimums de l'énergie E , obtenue en considérant en tout point la valeur minimum $E(\omega_\theta)$. Les points présentant les valeurs les plus basses, correspondant donc aux positions auxquelles les indicateurs ont le mieux réagi pour un modèle de forme à une orientation donnée, sont situés sur les grains extérieurs des amas. Ces résultats illustrent l'utilisation des indicateurs visant à détecter les grains de l'extérieur vers l'intérieur des amas. La figure 4.6 permet de visualiser les valeurs sur une image originale.




FIGURE 4.6 – Zoom sur image originale (gauche), sur carte des minimums de l'énergie E (milieu) et image d'illustration superposant les deux (droite).

4.2.4 Tenseur de structure

Le calcul des indicateurs est réalisé pour chaque objet modèle et pour un nombre d'orientations donné. De manière évidente, plus le pas sur l'orientation est fin, mieux les indicateurs réagissent. Cela facilite également la progression du contour actif, la forme de départ est alors mieux positionnée. Cependant, on ne peut se permettre d'avoir un pas sur l'orientation trop fin, cela impacte directement sur le temps d'exécution. Nous avons donc décidé d'introduire l'utilisation d'un tenseur de structure pour déterminer de manière précise l'orientation des objets, tout en considérant un nombre d'orientations réduit pour le calcul des indicateurs.

Le tenseur de structure est un outil de prétraitement qui peut être utilisé sur des images d'amas grains à haute densité [31], nous allons détailler la méthode dans cette section. Le tenseur de structure a été adapté au traitement d'image à la fin des années 1980 par Fostner et Gülch [22]. Il était alors utilisé pour la détection de points d'intérêt dans une image. Cet outil a par la suite été appliqué à d'autres problématiques : analyse de texture [26], représentation d'image d'écoulement [49] ou encore problème de flot optique [33]. Les résultats présentés dans ces publications démontrent la robustesse et la précision du tenseur de structure. La méthode proposée présente également l'intérêt d'être rapide et invariante aux changements de contraste.

Définition

Le tenseur de structure d'une image u est défini tel que :

$$T = G_\rho \star (\nabla u_\sigma \nabla u_\sigma^T), \quad (4.10)$$

avec $u_\sigma = G_\sigma \star u$, u une image en niveaux de gris, G_σ et G_ρ désignant des filtres gaussiens d'écarts types respectifs $\sigma \geq 0$ et $\rho \geq 0$. Ces filtres contrôlent respectivement le niveau de pré et post flou. Le paramètre σ est appelé échelle intérieure et le paramètre ρ échelle extérieure. Dans le cas d'une image couleur, le tenseur de structure est obtenu en considérant la somme des tenseurs de structure de chaque canal.

En pratique, l'opérateur de gradient ∇ est défini par $\nabla = (\partial_1, \partial_2)^T$. Les expériences menées dans le domaine l'ont été en définissant les opérateurs pseudo-différentiels ∂_i comme des convolutions basés sur des noyaux discrets. D'un point de vue asymptotique, tout noyau menant à une discrétisation consistante fournit de bons résultats. D'autre part, la structure du noyau est primordiale pour fournir des estimations anisotropiques et des valeurs d'orientation correctes. Les propriétés principales de tels noyaux discrets sont [58] :

- invariance en rotation, assurant une estimation fiable de l'orientation ;
- séparabilité, permettant un calcul rapide ;
- pas de décalage, ce qui implique l'utilisation de différences finies centrées.

En s'appuyant sur ces critères, Weickert et al. [58] suggèrent les définitions suivantes :

$$\partial_x u = \frac{1}{32} \begin{pmatrix} -3 & 0 & 3 \\ -10 & 0 & 10 \\ -3 & 0 & 3 \end{pmatrix} \star u \quad \text{and} \quad \partial_y u = \frac{1}{32} \begin{pmatrix} -3 & -10 & -3 \\ 0 & 0 & 0 \\ 3 & 10 & 3 \end{pmatrix} \star u.$$

Le gradient est calculé dans le domaine spatial, alors que les convolutions avec G_σ et G_ρ sont basées sur la transformée de Fourier rapide. En pratique, le temps de calcul du tenseur de structure ne pose pas de problème, sa complexité n'étant pas d'un ordre élevé : pour une image de n pixels, elle est de $\mathcal{O}(n \log(n))$. En chaque pixel, l'orientation est donnée par la direction du vecteur propre associé à la plus grande valeur propre du tenseur de structure.

Estimation du paramètre de post flou

Comme nous l'avons vu précédemment, le tenseur de structure introduit deux paramètres d'échelles, σ pour l'échelle intérieure et ρ pour l'échelle extérieure. Nous avons déterminé de manière empirique qu'il était possible de définir $\sigma = 0$. En effet, la bonne qualité des images et la faible présence de bruit permettent de s'affranchir de cette opération sans nuire à la qualité des résultats fournis par le tenseur de structure. D'autre part, par expérience également, nous avons pu observer que le paramètre ρ est lié à la forme des objets, et plus particulièrement à leur largeur. Pour représenter la largeur d'un objet, nous considérons les valeurs en pixels du petit axe d'une ellipse modélisant l'objet.

Dans le but d'établir la relation qu'il existe entre ces valeurs et ainsi déterminer la valeur optimale de ρ , une base de données de vérité terrain a été créée. Un opérateur humain a pour cela déterminé sur différentes images d'amas de grains les orientations de chaque grain. Les images de vérité terrain sont présentées sur les figures 4.8, 4.9, 4.10 et 4.11. La valeur optimale de ρ peut être définie comme la valeur minimisant la moyenne ou la médiane de l'erreur d'orientation obtenue par le tenseur de structure, en calculant la différence en valeur absolue avec les orientations fournies par la vérité terrain comme références. Les courbes présentées en figure 4.7 illustrent l'influence de la valeur de ρ sur l'erreur moyenne et médiane entre les orientations en valeur absolue.




FIGURE 4.7 – Influence de la valeur de ρ sur la moyenne (gauche) et la médiane (droite) de l'erreur en valeur absolue.

Les grains de riz, blé, orge de type 1 et de type 2 sont représentés respectivement par des étoiles rouges, des curseurs verts, des cercles bleus et des croix noires. Dans chaque cas, la valeur optimale du paramètre de post flou ρ est égale à environ un quart de la longueur en pixels du petit axe.

Les figures 4.8, 4.9, 4.10 et 4.11 présentent une comparaison entre les orientations fournies par la vérité terrain (en rouge) et par estimation (en vert) sur des lots de riz, d'orge de type 1, d'orge de type 2 et de blé. Chaque lot de grains compte une centaine d'objets. La table 4.1 présente les statistiques sur les erreurs d'orientation en valeur absolue de chacun des lots. Sur les 4 lots étudiés, l'erreur est en moyenne de 2 à 3 degrés, tout comme l'écart type associé. La médiane est d'environ 2 degrés.

TABLE 4.1 – Statistiques sur l'erreur d'orientation en valeur absolue.

Grains	ρ	Minimum	Maximum	Moyenne	Médiane	Écart type
Riz	3	0.150	14.833	2.806	2.266	2.629
Blé	5	0.023	15.025	2.628	1.798	2.494
Orge 1	5	0.043	24.473	2.266	1.572	2.722
Orge 2	6	0.006	9.274	2.464	1.825	2.202

Les erreurs significatives d'estimation sont peu nombreuses, la figure 4.12 présente deux cas où l'estimation n'est pas correcte, ce qui s'explique en partie par des conditions particulières : grains cassés ou recouvrement. Le tenseur de structure permet donc d'obtenir une estimation fiable des orientations des objets disposés en amas : cela nous permet de considérer un nombre d'orientations réduit pour le calcul des indicateurs, l'information donnée par le tenseur de structure étant alors utilisée lorsque qu'une approximation plus précise de l'orientation d'un objet est nécessaire. La figure 4.13a illustre l'utilisation du tenseur de structure : l'information qu'il fournit sur l'orientation permet d'affiner le positionnement du modèle de forme.




FIGURE 4.8 – Comparaison entre vérité terrain (gauche) et estimation (droite) sur un lot de grains de riz.




FIGURE 4.9 – Comparaison entre vérité terrain (gauche) et estimation (droite) sur un lot de grains de blé.




FIGURE 4.10 – Comparaison entre vérité terrain (gauche) et estimation (droite) sur un lot de grains d'orge de type 1.




FIGURE 4.11 – Comparaison entre vérité terrain (gauche) et estimation (droite) sur un lot de grains d'orge de type 2.




FIGURE 4.12 – Détails de deux mauvaises estimations de l'orientation par le tenseur de structure.




FIGURE 4.13 – Détails d'une image d'amas de grains de riz et positionnement du modèle de forme à l'orientation considérée par les indicateurs pour un pas de 10 degrés (140 degrés, en vert), et à l'orientation fournie par le tenseur de structure (144.8 degrés, en bleu).

4.2.5 Contour actif

Les informations fournies par les indicateurs, qui sont en partie basés sur des modèles de forme obtenus par modélisation d'ellipses, de superellipses ou des descripteurs de Fourier, ne constituent qu'une approximation du contour d'un éventuel objet à une position donnée. Le tenseur de structure permet d'obtenir une approximation plus précise de son orientation, mais il était nécessaire de mettre en place une méthode permettant d'obtenir les contours réels de l'objet.

L'objectif étant d'obtenir un contour précis depuis une approximation de celui-ci, le choix s'est porté vers une méthode de contour actif. Pour cela, nous nous sommes basés sur les travaux de Bresson et al. [6], qui introduit une méthode de contour actif avec a priori de forme. Cela est en effet parfaitement adapté à notre problématique : nous savons que tous les objets présentent une forme relativement générique et semblable aux modèles de forme définis durant l'étape du même nom, tout en présentant des variations. L'utilisation d'une méthode de contour actif comportant un terme d'a priori prend donc tout son sens.

La méthode originelle de Bresson est basée sur trois termes : un terme relatif à la notion de frontière, un terme relatif à la notion de région et un terme relatif à la notion de forme. L'objectif d'une telle méthode est donc d'optimiser une grandeur réunissant ces termes sous la forme d'une somme, avec des coefficients de pondération qui leurs sont associés. La formule générique est donc :

$$F = \beta_{fr}F_{\text{frontière}} + \beta_{fo}F_{\text{forme}} + \beta_rF_{\text{région}}. \quad (4.11)$$

avec β_{fr} , β_{fo} et β_r les coefficients de pondération des trois termes respectivement frontières, forme et région.

Une des principales difficultés quant à la mise en œuvre d'une méthode de contour actif est le nombre important de paramètres. En effet, de nombreux coefficients et pondérations sont utilisés dans ce type de méthodes. Il nous a donc fallu déterminer quelles étaient les valeurs optimales afin d'adapter au mieux ces coefficients et paramètres à notre type d'objets. Pour cela, nous avons utilisé une image de taille réduite, 152 par 110 pixels, ne comportant qu'un petit nombre de grains de riz. Cette image est présentée en figure 4.14a. Une vérité terrain a été réalisée sur cette image pour être utilisée comme référence, afin de pouvoir confronter les résultats obtenus en utilisant les contours actifs, elle est présentée en figure 4.14b.

Les tests ont permis d'établir le jeu de paramètres le plus adapté à la problématique de détection de grains. La sélection de ce jeu de paramètre a été réalisée en considérant les techniques d'évaluation de détection présentées dans la section 4.4 en confrontant les nombreux résultats obtenus avec l'image de vérité terrain. Des exemples de résultats obtenus sont présentés en figure 4.15.

Le terme de région permet de s'assurer que la zone à l'intérieur du contour est ho-



FIGURE 4.14 – Image de 152×110 pixels utilisée pour déterminer les paramètres de la méthode de contour actif.




FIGURE 4.15 – Exemples de résultats obtenus avec variation des paramètres de la méthode de contour actif.

mogène. Or dans notre cas, il est assez courant que les grains ne soient pas de couleurs homogènes pour différentes raisons : tâches, stries notamment. D'autre part, le calcul de ce terme est particulièrement long, il faut accéder aux valeurs de chaque pixel appartenant à l'intérieur du contour. Ce terme a donc été ignoré ($\beta_r = 0$).

Le terme de frontière permet d'attirer le contour actif dans les zones présentant des variations de valeurs importantes, il est basé sur l'utilisation du gradient. Dans le but de favoriser les mouvements du contour actif et sa stabilité sur les frontières entre le fond et les objets, les données utilisées pour le terme de frontière sont obtenues selon la méthode suivante :

- une première image I_F est calculée depuis l'image convertie en niveaux de gris, par sélection du canal valeur du modèle TSV, selon la formule suivante :

$$I_F = \frac{1}{1 + \gamma_f \times \|\nabla u\|} \quad (4.12)$$

avec ∇u le gradient de l'image, $\|\cdot\|$ la norme euclidienne et γ_f un coefficient de pondération fixé à 2 de manière empirique.

- seules les valeurs de l'image I_F situées sur de la matière sont conservées, en utilisant l'image binaire objets/fond ;
- on attribue aux pixels situés sur les frontières entre les objets et le fond la valeur minimum de I_F , l'image obtenue est notée I_{F_n} .

Les pixels situés sur les frontières entre matière et fond sur l'image I_{F_n} ont donc tous la même valeur, correspondant à un gradient maximum. Cela permet de favoriser les mouvements du contour actif vers ces frontières tout en limitant ces mouvements une fois positionné dessus. La figure 4.16 présente trois exemples d'images I_{F_n} définissant le terme de frontière de la méthode de contour actif.




FIGURE 4.16 – Exemples d'images I_{F_n} (bas) utilisées pour définir le terme de frontière de la méthode de contour actif obtenue pour depuis des images en niveaux de gris (haut).

Le terme d'a priori de forme permet de contraindre le contour actif à ne pas s'éloigner d'une forme préalablement apprise. Les formes utilisées pour définir ce terme sont les formes issues de l'apprentissage de modèles de forme.

Le nombre d'itérations nécessaires sur des objets tels que des grains n'est pas très élevé : le contour initial utilisé comme point de départ de la méthode de contour actif est en effet peu éloigné de la frontière réelle de l'objet. Le nombre maximum d'itérations nécessaires à la méthode pour converger a donc été fixé à 100 de manière empirique. Dans les faits, seule un vingtaine d'itérations sont généralement nécessaires pour que le contour soit stabilisé. Les conditions d'arrêt sont les suivantes :

- l'aire de l'objet formé par le contour est supérieur au seuil maximum, le contour

- s'est trop éloigné du contour initial en direction de l'extérieur ;
- l'aire de l'objet formé par le contour est inférieur au seuil minimum, le contour s'est trop éloigné du contour initial en direction de l'intérieur ;
- la position du contour n'a pas évolué pendant 10 itérations successives, l'absence de mouvement du contour indique sa stabilité ;
- le nombre d'itérations maximum a été atteint.

La figure 4.17 présente des exemples de résultats obtenus par la méthode de contour actif avec a priori de forme sur des grains de riz.




FIGURE 4.17 – 6 exemples de résultats obtenus à l'issue de la méthode de contour actif avec a priori de forme : les contours initiaux et finaux apparaissent respectivement en bleu et en vert.




FIGURE 4.18 – Exemples d’objets non validés avec le contour initial en bleu et le contour retourné par la méthode de contour actif en rouge.

4.2.6 Validation d’un objet détecté

L’ultime étape de la détection d’un objet consiste à le valider. Il s’agit de s’assurer que le résultat retourné par la méthode de contour actif correspond bien au type d’objets recherchés et que la méthode de détection n’a pas commis d’erreur. Ces erreurs peuvent avoir différentes origines :

- au niveau du calcul de l’énergie depuis les 4 indicateurs, des cas de dispositions et de formes particulières des objets peuvent fournir une énergie laissant présager de la présence d’un objet alors qu’il y en a plusieurs (figure 4.18a) ;
- au niveau de la méthode de contour actif, celle-ci peut être amenée à s’éloigner de façon trop lointaine du contour initial, dans la direction intérieure ou extérieure, conduisant ainsi à un contour ne correspondant plus à celui d’un objet (figure 4.18b).

Il convient donc de vérifier que le résultat obtenu à l’issue de la méthode de contour actif est valide. Pour cela, on utilise les attributs enregistrés lors de l’étape d’apprentissage de modèles de forme. Ces données propres à chacun des objets utilisés lors de cette étape, représentent une source d’information que l’on synthétise sous la forme de valeurs minimum et maximum, de moyenne et d’écart type. On établit ainsi des intervalles de tolérance pour chacun des attributs afin de vérifier que lors de la détection, l’objet supposé répond aux critères fixés par ces intervalles. Les attributs de l’objet détecté sont donc calculés et mis en regard avec les intervalles établis grâce aux données de l’apprentissage de modèles de forme. L’objet retourné par la méthode de contour actif sur la figure 4.18c n’a pas été validé, sa circularité ne correspondant pas aux critères établis par les données récoltées lors de l’apprentissage de modèles de forme.

4.3 Méthodes de détection

Nous allons maintenant nous intéresser aux méthodes de détection qui ont été mises au point pour traiter la problématique de segmentation des grains dans une image. Deux méthodes ont été développées, une déterministe et une probabiliste. Ces deux méthodes reposent sur l'utilisation des différents outils présentés dans la section précédente.

La méthode probabiliste a été développée en s'inspirant des travaux menés par Perrin sur la détection de houppiers depuis des images aériennes couleur infrarouge [44]. Ces travaux sont basés sur l'exploitation des processus ponctuels marqués qui sont utilisés dans un contexte stochastique pour modéliser un nombre inconnu a priori d'objets et pour extraire leurs positions et leurs tailles dans l'image. Cette méthode est adaptée aux images d'arbres isolés tout comme aux images de végétation dense. Elle a été utilisée pour des applications variées : détecter des bateaux dans un port maritime sur des images de télédétection [3] ou encore compter des flamants roses sur des images aériennes [9].

Les conditions dans lesquelles ces travaux ont été menés présentent des points communs avec notre problématique :

- le nombre d'objets à détecter est élevé mais inconnu ;
- la forme de ces objets varie autour d'une forme générique ;
- les objets ne sont pas positionnés de manière ordonnée dans l'image, mais peuvent être contraints : alignement dans le cas de bateaux dans un port ; recouvrement limité entre les objets dans le cas de houppiers ou de grains.

Nous nous sommes donc intéressés à adapter cette méthode à la détection de grains dans une image (4.3.1). Cependant, d'un point de vue industriel, la reproductibilité des résultats est un enjeu essentiel. La méthode fournie en réponse à la problématique de détection doit obligatoirement fournir les mêmes résultats pour une image et un jeu de paramètres donnés. Nous nous sommes donc également intéressés à la mise au point d'une méthode de détection déterministe, présentée dans la section 4.3.2.

Les deux méthodes sont basées sur l'exploitation des informations fournies par assemblage des quatre indicateurs sous forme d'énergies $E(\omega_\theta)$. Le calcul de ces cartes d'énergie $E(\omega_\theta)$ et de la carte des minimums de l'énergie E représente une étape initiale commune aux deux méthodes. Ces deux méthodes ont donné lieu aux publications suivantes : méthode probabiliste [15], méthode déterministe [17] et comparaison des deux méthodes [16].

4.3.1 Approche probabiliste

La méthode probabiliste est basée sur les processus ponctuels marqués. Cette notion a été longtemps utilisée pour schématiser des phénomènes stochastiques temporels tels que les files d'attente. Plus récemment cette approche a été utilisée pour extraire des objets au sein d'images dans diverses applications : détection de routes dans des images aériennes [30] ou encore la détection et le recensement d'arbres [44].




FIGURE 4.19 – Position et marques d'une ellipse




FIGURE 4.20 – Objet x_i et $\mathcal{F}(x_i)$ sa couronne (a), et leur équivalent discrétisé (b).

Nous présentons dans cette partie les principales définitions et quelques propriétés sur les processus ponctuels marqués nécessaires à la compréhension de leur application au traitement d'image. Des détails plus approfondis peuvent être trouvés dans les travaux de Descombes [11].

Généralités

Nous cherchons à détecter des objets au sein d'une image : des grains de céréales non ordonnés mais disposés de manière à limiter les recouvrements. Ces objets sont caractérisés par leurs positions et leurs attributs géométriques. L'espace des objets est noté χ , tel que $\chi = P \times M$, avec P l'espace dans lequel nous exprimons les positions des objets dans l'image et M l'espace des marques ou attributs géométriques décrivant l'objet. Dans ce cadre, une configuration notée \mathbf{x} d'objets de χ est une liste non-ordonnée d'objets :

$$\mathbf{x} = \{x_1, \dots, x_n\}, n \in \mathbb{N}, x_i \in \chi, i = 1, \dots, n. \quad (4.13)$$

Un processus ponctuel marqué sur χ , aussi appelé processus objet, noté X , est un processus ponctuel sur χ dont les positions des objets sont dans P et les marques dans M .

Un processus ponctuel marqué X sur χ est une variable aléatoire dont les réalisations sont des configurations aléatoires de points sur l'espace des positions P , auxquels sont ajoutées des marques appartenant à l'espace des marques M . Dans notre cas, les objets à détecter sont des grains que l'on peut représenter :

- par une ellipse, les marques d'une ellipse peuvent alors être son orientation, son petit axe et son grand axe ;
- par une superellipse, les marques peuvent alors être son orientation, son petit axe, son grand axe et sa puissance ;
- par des descripteurs de Fourier, les marques pouvant alors être l'orientation et un nombre fini de descripteurs de Fourier.

La figure 4.19 illustre la notion de marques : dans le cas d'une ellipse, les marques sont l'orientation, la longueur du grand axe et celle du petit axe de l'ellipse.

Les processus ponctuels de Markov, ou processus de Gibbs, sont les plus utilisés en traitement d'images. Ces processus sont définis par leur densité par rapport à une mesure de Poisson de référence. Cette densité peut s'écrire sous forme énergétique :

$$f(\mathbf{x}) = \frac{1}{Z} \exp(-U(\mathbf{x})) \quad (4.14)$$

où l'énergie du processus de Gibbs est notée $U(\mathbf{x})$, et Z est une constante de normalisation définie par :

$$Z = \int_{\mathbf{x} \in \chi} \exp(-U(\mathbf{x})) d\mathbf{x}. \quad (4.15)$$

L'énergie du processus peut être définie comme la somme de différents termes. On en distingue généralement deux : un terme dit d'*attache aux données*, noté $U_d(\mathbf{x})$, qui représente la "vraisemblance" du processus ponctuel marqué par rapport aux données (l'image dans notre cas), regroupant les données que l'on a sur les objets eux-mêmes ; et un terme dit *a priori*, noté $U_p(\mathbf{x})$, qui impose des conditions sur la configuration \mathbf{x} .

Dans le cadre de la détection d'objets dans une image, on cherche la configuration \mathbf{x} d'objets la plus probable, c'est-à-dire celle qui minimise l'énergie $U(\mathbf{x})$. Les sections suivantes sont consacrées aux définitions des termes composant l'énergie à minimiser, puis à la méthode d'optimisation utilisée.

Énergie $U(\mathbf{x})$

Comme nous l'avons introduit précédemment, l'énergie $U(\mathbf{x})$ est la somme des termes d'attache aux données $U_d(\mathbf{x})$ et a priori $U_p(\mathbf{x})$:

$$U(\mathbf{x}) = U_d(\mathbf{x}) + \gamma U_p(\mathbf{x}) \quad (4.16)$$

avec γ un coefficient permettant de définir le poids du terme d'a priori par rapport au terme d'attache aux données. Ce coefficient est déterminé de manière empirique.

Le terme $U_d(\mathbf{x})$ prend en compte les données de l'image par rapport aux objets. Nous définissons $U_d(\mathbf{x})$ en utilisant une distance de Bhattacharya modifiée, notée d_B , telle que Descamps et al. la définissent dans [10] :

$$d_B(x_i, \mathcal{F}(x_i)) = \frac{(\mu_1 - \mu_2)^2}{4\sqrt{\sigma_1^2 + \sigma_2^2}} - \frac{1}{2} \log \left(\frac{2\sigma_1\sigma_2}{\sigma_1^2 + \sigma_2^2} \right) \quad (4.17)$$

avec un objet $x_i \in \chi$ et $\mathcal{F}(x_i)$ la couronne de l'objet x_i (figure 4.20), (μ_1, σ_1) et (μ_2, σ_2) étant respectivement les moyennes et les variances des valeurs radiométriques des pixels de l'objet et de sa couronne.

Le calcul de cette distance nous permet de mettre en avant les zones présentant un contraste important entre l'objet et sa couronne, il permet de plus de prendre en compte l'homogénéité des zones étudiées. On a finalement :

$$U_d(\mathbf{x}) = \sum_{x_i \in \mathbf{x}} U_d(x_i) = \sum_{x_i \in \mathbf{x}} \mathcal{Q}(d_B(x_i, \mathcal{F}(x_i))) \quad (4.18)$$

avec $\mathcal{Q}(d_B) \in [-1, 1]$ une fonction de qualité qui favorise ou pénalise les objets par rapport à un seuil d_0 donné :

$$\mathcal{Q}(d_B) = \begin{cases} (1 - \frac{d_B}{d_0}) & \text{si } d_B < d_0, \\ \exp\left(-\frac{d_B - d_0}{100}\right) - 1 & \text{si } d_B \geq d_0. \end{cases} \quad (4.19)$$

Les objets présentant un contraste important avec les couronnes externes ($d_b < d_0$) sont ainsi favorisés et l'énergie qui leur est associée est négative.

Le terme $U_p(\mathbf{x})$ renseigne sur les connaissances a priori que l'on possède sur la configuration recherchée, comme les interactions entre les objets. Dans le cadre de notre application, $U_p(\mathbf{x})$ est un terme de répulsion qui pénalise les recouvrements entre les objets. Pour chaque objet $x_i \in \chi$, $U_p(x_i)$ est la somme des forces de répulsion émises par les objets qui interagissent avec lui, c'est-à-dire les objets qui sont en recouvrement avec lui. Ces forces de répulsion sont calculées en comptant le nombre de pixels communs entre l'objet x_i et les objets x_j composant son voisinage notés $\mathcal{V}(x_i)$:

$$\begin{cases} U_p(\mathbf{x}) &= \sum_{x_i \in \mathbf{x}} U_p(x_i) \\ U_p(x_i) &= \sum_{x_j \in \mathcal{V}(x_i)} \mathcal{A}(x_i \cup x_j) \end{cases} \quad (4.20)$$

avec $\mathcal{A}(x_i \cup x_j)$ l'aire commune aux objets x_i et x_j .

Optimisation

La détection d'objets par utilisation des processus ponctuels marqués est généralement réalisée par une optimisation d'énergie à l'échelle de la configuration [12, 44]. Dans le cadre de notre problématique, cette optimisation est réalisée à l'échelle de l'objet. Pour cela, on considère une dynamique de naissances et morts multiples à laquelle on associe la méthode de contour actif avec a priori de forme.

Cette dynamique de naissances et morts multiples, définie par Descombes et al. dans [12], réalise l'échantillonnage du processus, la méthode de contour actif avec a priori de forme est ajoutée en étape intermédiaire pour réaliser l'optimisation de l'énergie associé à un objet.

L'algorithme de la dynamique de naissances et morts multiples se décompose en trois étapes majeures qui sont réalisées alternativement et itérativement : naissance, détection et mort. Deux paramètres sont initialisés avant la première itération puis sont mis à jour à la fin de chaque itération : un paramètre de température inverse φ et un paramètre de discrétisation δ . Ces paramètres permettent d'affiner les probabilités de naissances et de morts.

L'étape de naissance met en jeu des probabilités B associées à tout point de l'image : ces probabilités sont obtenues en considérant la carte des minimums de l'énergie E obtenue depuis les 4 indicateurs I_1 , I_2 , I_3 et I_4 . Durant l'étape de naissance également, les marques de l'objet créé sont choisies avec les probabilités $M(p)$ associées aux différentes énergies $E(\omega_\theta)$.

Les figures 4.21a, 4.21b et 4.21c illustrent sous la forme de diagrammes les trois étapes de la dynamique de naissances et morts multiples qui sont détaillées ci-dessous :

- **Étape de naissance.** Pour tout pixel p de l'image présentant une probabilité $B(p) \neq 0$, si aucun objet n'est déjà présent, on ajoute un objet avec la probabilité $\delta B(p)$, où δ est un coefficient de discrétisation et $B(p)$ la probabilité obtenue depuis la carte des minimums de l'énergie E . Les marques de l'objet ajouté sont choisies avec une probabilité $M(p)$, obtenue depuis les cartes d'énergie $E(\omega_\theta)$.
- **Étape de détection.** Pour tout objet créé à l'étape précédente, on calcule l'énergie d'attache aux données $U_d(x_p)$ qui lui est associée, puis on classe l'ensemble des objets de la configuration courante selon leur énergie d'attache aux données, de la plus petite à la plus grande. On parcourt alors les objets selon ce classement pour comparer la valeur de leur énergie d'attache aux données avec un seuil U_{d_0} : si elle est supérieure, on passe à l'étape suivante ; si elle est inférieure, alors la méthode de contour actif avec a priori de forme est utilisée en considérant comme contour initial celui donné par la position et les marques de l'objet considéré. Le résultat est alors soumis au principe de validation présenté en section 4.2.6. Si l'objet est validé, il est considéré comme détecté et on considère le prochain objet dans la liste.
- **Étape de mort.** Pour chaque objet x_p pris dans cet ordre de classement, on calcule son taux de mort :

$$D(x_p) = \frac{\delta a_\varphi(x_p)}{1 + \delta a_\varphi(x_p)} \mathbf{x} \quad (4.21)$$

avec $a_\varphi(x_p) = \exp(-\varphi U(x_p))$. L'objet est alors supprimé avec la probabilité $D(x_p)$.

À l'issue de l'étape de mort, les paramètres φ et δ sont mis à jour et l'algorithme reprend à l'étape de naissance.

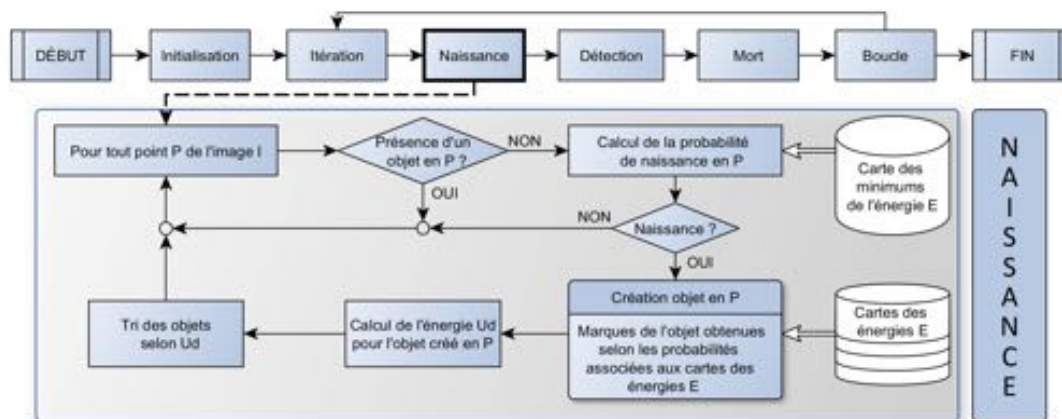
L'échantillonnage du processus par une dynamique de naissances et morts multiples met en jeu un certain nombre de paramètres : le coefficient γ de poids entre le terme d'attache aux données et le terme d'a priori, le coefficient δ de discrétisation du processus, le seuil d_0 . Ces paramètres sont sensibles et nécessitent d'être ajustés de manière empirique en fonction du type d'objets à détecter.

Durant l'étape de détection, si l'objet considéré est validé, les différentes cartes d'énergie $E(\omega_\theta)$ sont mises à jour localement : tous les pixels de l'objet détecté sont considérés comme appartenant au fond, puis les indicateurs I_1 , I_2 , I_3 et I_4 sont calculés.

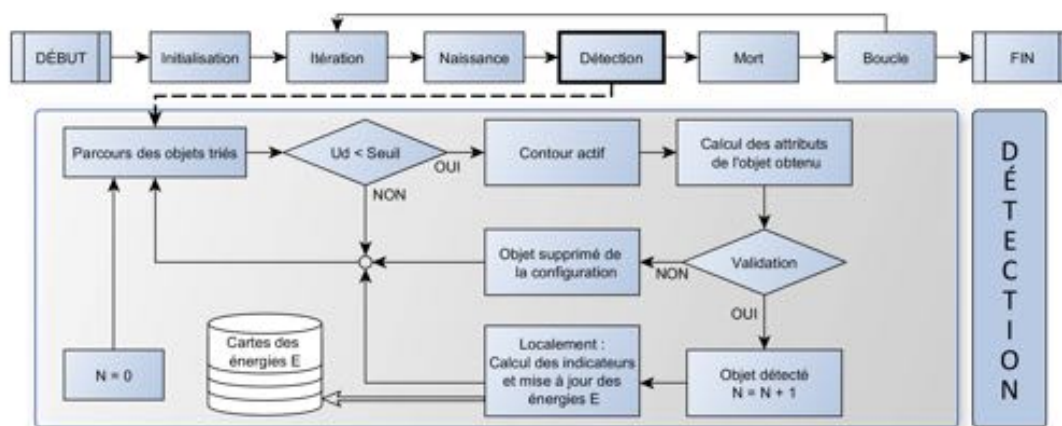
La segmentation est terminée dès lors qu'il n'y a plus de matière à détecter en quantité suffisante, cette quantité étant définie par rapport à l'aire minimale d'un objet obtenue lors de l'apprentissage de modèles de forme.

4.3.2 Approche déterministe

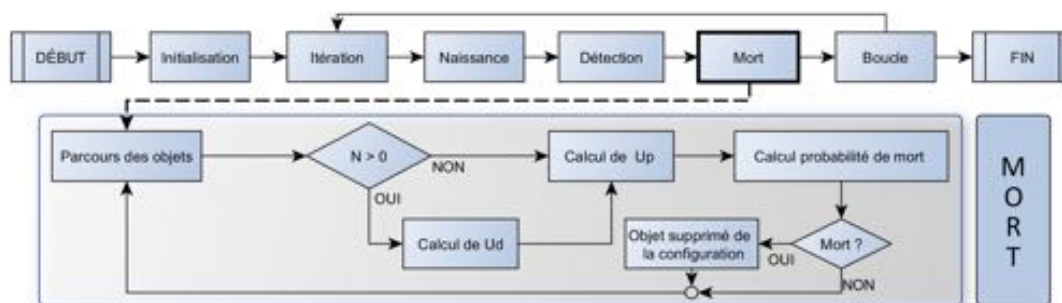
Tout comme l'approche probabiliste, l'approche déterministe utilise les informations des cartes d'énergie $E(\omega_\theta)$. La première étape consiste à rechercher la valeur minimum



(a) Étape de naissance



(b) Étape de détection



(c) Étape de mort

FIGURE 4.21 – Diagrammes des trois étapes de la dynamique de naissances et morts multiples.

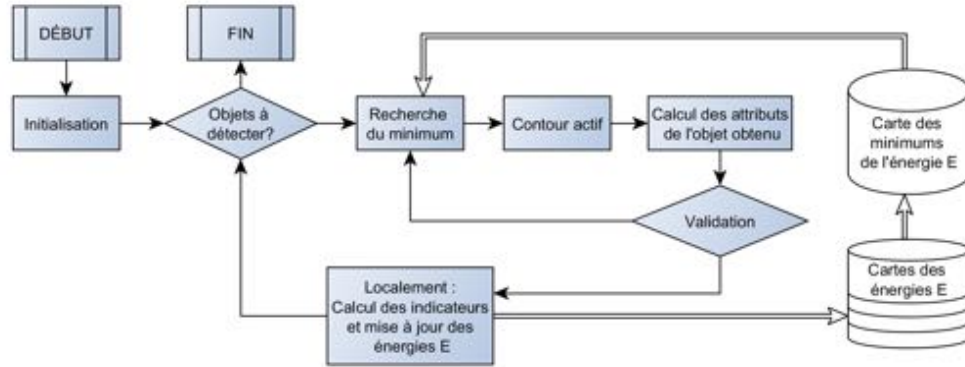


FIGURE 4.22 – Diagramme de la réalisation de la méthode de segmentation déterministe.

au sein de la carte des minimums d'énergie E , cette valeur correspond à un modèle de forme considéré à une position et une orientation, pour lesquels les indicateurs ont le mieux réagi. Cette forme est alors utilisée comme contour initial de la méthode de contour actif avec a priori de forme. Le résultat retourné est alors soumis à validation afin d'établir s'il s'agit d'un objet correctement détecté. Deux cas apparaissent : l'objet est validé ou bien rejeté.

Si l'objet est validé, on procède alors aux opérations suivantes :

- l'objet est effacé de la carte des minimums de l'énergie E : tous les pixels appartenant à l'objet sont considérés comme appartenant désormais au fond de l'image ;
- les cartes d'énergie $E(\omega_\theta)$ sont localement mises à jour : les indicateurs et l'énergie qui en découle sont calculés pour prendre en compte la disparition de l'objet ;

Si l'objet est rejeté, la valeur de la carte des minimums d'énergie E est mise à jour : elle est remplacée par la valeur minimum suivante en parcourant les cartes d'énergie $E(\omega_\theta)$ pour la position considérée, c'est à dire celle du centre de l'objet ayant été rejeté.

De manière itérative, deux principales étapes se succèdent :

- recherche de la valeur minimum au sein de la carte des minimums de l'énergie E ;
- détection d'objets par la méthode de contour actif.

Le diagramme présenté en figure 4.22a illustre les différentes étapes de cette approche.

4.4 Techniques d'évaluation de la détection

Dans le but d'évaluer la qualité de la détection des grains dans l'image, il est apparu nécessaire de comparer les résultats obtenus avec une vérité terrain. Deux problématiques apparaissent alors : tout d'abord, comment obtenir une image de référence qui sera utilisée comme vérité terrain, puis, comment comparer les résultats obtenus par nos méthodes avec cette référence ? Pour obtenir des images de vérité terrain, il a été demandé à un opérateur humain de définir les frontières des objets dans une image. Cela

a été réalisé manuellement, l'opérateur pointant les frontières depuis un logiciel d'édition d'image, il lui a été demandé de colorier les frontières et le fond en rouge sur une banque d'images tests. Des exemples d'images obtenues sont présentées sur la figure 4.23.




FIGURE 4.23 – Exemples d'images de vérité terrain.

Pour comparer deux résultats de détection, il est nécessaire de faire correspondre les objets détectés dans les deux images : la distance entre les barycentres des objets a été utilisée.

Des critères permettant d'évaluer la qualité des résultats de détection peuvent alors être calculés en adoptant les notations suivantes : $\bar{\omega}$ désigne les objets provenant d'une image de vérité terrain et ω ceux détectés par les méthodes déterministe ou probabiliste. Le premier critère est la distance entre les barycentres d'un même objet détecté dans les deux images, celle-là même utilisée pour établir les correspondances entre les images. Ce critère est noté e_b .

Les critères suivants sont basés sur les différences entre la valeur d'un attribut pour un objet issu de l'image de vérité terrain et celle pour un objet de l'image traitée par une de nos méthode. Ces critères sont :

- l'erreur sur l'orientation de l'objet, notée e_θ ;
- l'erreur sur l'aire de l'objet, notée e_a ;
- l'erreur sur le périmètre de l'objet, notée e_p .

Les formules utilisées pour calculer ces critères sont les suivantes :

$$e_b = \|b_{\bar{\omega}} - b_{\omega}\|; \quad (4.22) \quad e_\theta = |\theta_{\bar{\omega}} - \theta_{\omega}|; \quad (4.23)$$

$$e_a = |card(\bar{\omega}) - card(\omega)|; \quad (4.24) \quad e_p = |card(\partial\bar{\omega}) - card(\partial\omega)| \quad (4.25)$$

avec $card(\omega)$ le nombre de pixels de l'objet ω , b_ω le barycentre de ω , $\|\cdot\|$ la norme euclidienne et $\partial\omega$ le contour de ω .

Nous considérons également d'autres critères bien connus : le ratio de faux positifs noté FP ; le ratio de faux négatifs noté FN ; et le coefficient de similarité de Dice [13] noté D . Les définitions de ces critères sont les suivantes :

$$FP(\omega|\bar{\omega}) = card(\bar{\omega}^c \cap \omega); \quad (4.26)$$

$$FN(\omega|\bar{\omega}) = card(\bar{\omega} \cap \omega^c); \quad (4.27)$$

$$D(\bar{\omega}, \omega) = \frac{2card(\bar{\omega} \cap \omega)}{card(\bar{\omega}) + card(\omega)}; \quad (4.28)$$

avec ω^c le complémentaire de l'objet ω et $d(\cdot, \cdot)$ la distance euclidienne.

4.5 Résultats de la détection

Les premiers résultats s'intéressent à la comparaison entre la détection réalisée par un opérateur humain (images de vérité terrain) et par la méthode déterministe sur une image de haute densité de grains. La partie gauche de la table 4.2 présente le pourcentage d'objets détectés sur des images de haute densité : deux types de grains d'orges ainsi que des grains de riz et des grains de blé ont été considérés. Deux approches déterministes sont comparées, en considérant les images de vérité terrain comme référence, la première approche (notée E) et la seconde (notée SE) utilisent respectivement des modèles de forme de type ellipses et superellipses. Les résultats soulignent que le pourcentage de détection est meilleur en considérant la seconde approche utilisant la modélisation par superellipse. L'erreur moyenne sur la distance entre les barycentres de l'image de vérité terrain et celle considérée illustre la bonne détection des objets, aux bonnes positions. La figure 4.24 présente d'autres critères calculés pour ces deux approches : coefficient de similarité de Dice, ratios de faux positifs et de faux négatifs. Les lignes rouges et vertes représentent respectivement la valeur moyenne et la valeur moyenne plus ou moins l'écart type. La figure 4.26 présente une comparaison visuelle sur les images de grains d'orge.

La figure 4.25 établie la comparaison entre les méthodes déterministe et probabiliste. Le principal avantage de la méthode déterministe est sa capacité à être reproductible. La méthode probabiliste peut fournir de meilleurs ou de moins bons résultats. La figure 4.27 présente des résultats obtenus sur des grains de riz par les méthodes déterministes et probabilistes.

Dans le but d'évaluer la robustesse des outils mis en œuvre et l'influence de la densité des grains sur les résultats de détection, des tests ont été réalisés pour cinq densités différentes d'un même échantillon composé de 100 grains de riz (figure 4.28). Les images de

TABLE 4.2 – Pourcentage d’objets détectés et erreur moyenne sur les barycentres.

Pourcentage d’objets détectés			Erreur moyenne e_b	
E	SE	Grains	E	SE
100	100	Orge 1	1.99	2.22
98	98	Orge 2	0.94	0.88
98	100	Riz	1.28	1.16
99	100	Blé	0.91	0.79

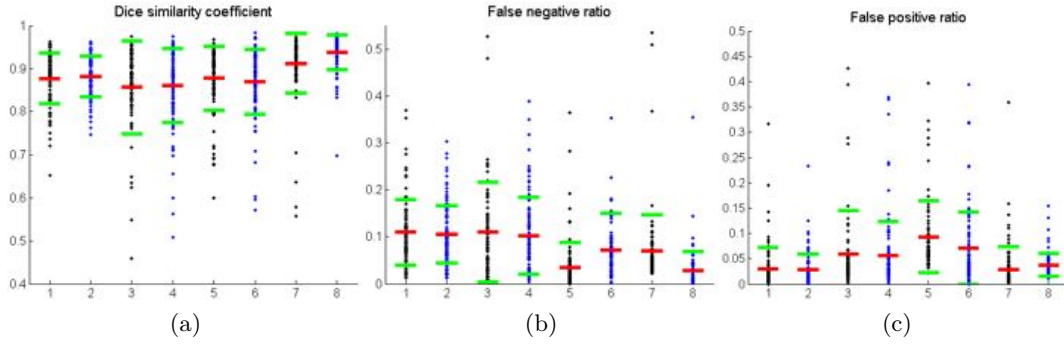



FIGURE 4.24 – Orge 1 E (1), orge 1 SE (2), orge 2 E (3), orge 2 SE (4), riz E (5), riz SE (6), blé E (7), blé SE (8)

densités extrêmes sont présentées en figure 4.28. L’objectif est également de déterminer si il est possible de reconnaître un échantillon malgré des variations extrêmes de la densité des objets. Parmi les données obtenues pour chaque objet à l’issue de la détection, les valeurs des petits axes, grands axes, périmètres et aires ont été utilisés pour tracer les courbes de distributions du paramètre considéré. Elles sont présentées en figure 4.29. Ces résultats, principalement en ce qui concerne le grand axe, le périmètre et l’aire, permettent de mettre en avant une robustesse intéressante quant à la capacité du système à détecter les grains sur des images de densité variable. Les résultats obtenus pour le petit axe sont moins stables, cela s’explique notamment par le fait que dans la méthode de détection, deux grains ne peuvent pas partager une même frontière.



(a)

(b)



(c)

(d)

FIGURE 4.25 – Images de détection de grains de riz et d’orge, méthode déterministe (gauche) et probabiliste (droite).





FIGURE 4.26 – Résultats de détection sur des images de grains d’orge. De haut bas : vérité terrain, méthode déterministe E et méthode déterministe SE. Les rectangles rouges situent les erreurs de détection.




(a)



(b)

FIGURE 4.27 – Images de détection obtenues par la méthode déterministe (haut) et par la méthode probabiliste (bas).




(a)




(b)


FIGURE 4.28 – Images d'un même échantillon de 100 grains de riz à différentes densités : grains isolés (4.28a) et haute densité (4.28b).




(a)



(b)



(c)



(d)

FIGURE 4.29 – Courbes de distributions (petit axe 4.29a, grand axe 4.29b, périmètre 4.29c et aire 4.29d) des grains de riz de l'échantillon présenté en figure 4.28 pour des densités croissantes allant de 1 (4.28a) à 5(4.28b).

Chapitre 5

Exploitations et perspectives

Le système mis au point pour traiter la problématique d'inspection visuelle de grains de céréales permet de réaliser l'acquisition et la détection des grains dans une image, même lorsque les grains sont présentés en amas. Ce chapitre présente dans un premier temps des exemples qui illustrent différentes exploitations qui peuvent être faites des informations extraites 5.1, avant de s'intéresser dans un second temps à des acquisitions réalisées à des longueurs d'ondes situées en dehors du visible, sur lesquelles les outils de détection sont utilisés 5.2.

5.1 Exploitations

Les travaux présentés dans les chapitres précédents visent à fournir à l'entreprise les données visuelles pour chaque grain détecté. Ces données sont ensuite exploitées par le logiciel Alpha Soft pour traiter la classification et fournir un résultat sur la qualité de l'échantillon et ainsi déterminer le prix du lot étudié. Deux applications sont présentées dans cette section : la première porte sur la classification de grains de riz selon un critère de taille, et la seconde s'intéresse au tri de pois selon leur couleur. Ces résultats ont été obtenus sans utiliser le logiciel Alpha Soft : l'intégration dans le logiciel de la librairie mise au point dans le cadre de cette thèse n'étant pas encore finalisée (en particulier les interfaces utilisateurs). Enfin, un indice de confiance est présenté, ce paramètre pouvant être utilisé pour déterminer le degré de certitude sur la détection.

5.1.1 Riz

La figure 5.1 présente des résultats d'inspection visuelle de grains de riz. L'application consiste à déterminer les proportions de grains entiers et de grains cassés dans l'échantillon analysé. L'échantillon analysé pour l'application est le même ayant été considéré pour évaluer la robustesse de la détection en fonction de la densité, l'image originale est présentée dans le chapitre 4 sur la figure 4.28. Sur cette même figure sont présentées les distributions des grains par rapport au grand axe, au périmètre et à l'aire. On peut remarquer sur ces courbes que des grains entiers et des grains cassés sont présents dans




FIGURE 5.1 – À gauche : distribution en aire des grains de riz présentés au chapitre 4 sur l’image de la figure 4.28 ; à droite : résultats sur l’image, les grains considérés cassés sont en rouge et les grains entiers en bleu.


l’échantillon. La figure 5.1a présente la distribution en aire des grains de riz sous forme d’histogramme, un pas de 20 unités (pixels) ayant été retenu pour discrétiser cette information. Depuis les données extraites de l’apprentissage, un seuil sur l’aire des grains est obtenu en ne considérant que les 50% de grains qui présentent les aires les plus importantes. L’échantillon analysé était composé de 20% de grains cassés et 80% de grains entiers. Les résultats fournis en établissant deux classes par rapport au seuil sur l’aire sont proches de ces valeurs. La figure 5.1b présente ces résultats sur une image avec les grains considérés cassés en rouge et les grains entiers en bleu. On note certaines erreurs de détection : quelques grains n’ont pas été détectés entièrement.

5.1.2 Pois

La figure 5.2 présente une classification de pois selon des critères de couleur. Les grains ont été détectés par la méthode déterministe. La couleur moyenne de chaque grain est ensuite calculée. Des classes ont été définies de manière empirique, basées sur des tolérances par rapport à des couleurs moyennes définies comme références. Chaque grain est alors affecté à une classe, représentée par une lettre sur la figure 5.2.

5.1.3 Indice de confiance

Un indice de confiance a été intégré aux méthodes de détection. Il s’agit d’une demande industrielle. Cette information peut être utilisée pour définir la qualité de l’échantillon et prévenir d’éventuels problèmes. Cet indice de confiance est basé sur les informations fournies par les indicateurs lors de la détection. La figure 5.3 illustre son utilisation : les objets détectés sont marqués d’une croix bleu, cyan ou rouge pour indiquer respectivement un indice de confiance sûr, bon ou mauvais. On peut noter que cet indice réagit dans les zones de recouvrements entre grains, en attribuant un indice de



(a)

FIGURE 5.2 – À gauche : image segmentée de pois avec une lettre sur chaque objet détecté, correspondant aux classes qui ont été définies sur des critères de couleur moyenne, illustrées à droite.

confiance mauvais, ce qui est positif. Cependant, il peut également réagir sur des grains dont les caractéristiques sont trop éloignées de celles des grains ayant été utilisés lors de l'apprentissage de modèles de forme.

5.2 Perspectives

5.2.1 Acquisitions proche infrarouge et ultraviolet

Les travaux de Mohan et al. [38] soulignent l'intérêt d'étudier des grains de céréales, particulièrement le blé, en considérant leurs réflectivités sur des longueurs d'ondes spécifiques, notamment dans le proche infrarouge. En effet, pour certaines longueurs d'ondes, il est possible d'évaluer la teneur en eau ou le taux d'impureté d'un grain de blé. Les longueurs d'ondes qu'ils ont déterminées comme pertinentes varient selon le paramètre à mesurer mais sont comprises entre 800 et 1430 nanomètres.

Nous nous sommes donc intéressés à étendre le domaine des acquisitions au proche infrarouge (NIR), mais également à l'ultraviolet (UV), afin, d'une part, de déterminer l'apport éventuel des informations qu'offrent ces deux domaines de longueur d'ondes, et d'autre part, d'évaluer l'intérêt d'intégrer des dispositifs de ce type dans le système d'acquisition.

Le matériel utilisé pour réaliser les acquisitions est composé de :

- un bloc caméra Basler intégrant un capteur monochrome CMOS 2/3 inch NIR, offrant une image de 2048 par 1088 pixels, couplé à un objectif de focale 8mm et ouvrant à $F1.4$;
- un éclairage annulaire de 9 LEDs NIR (850 nm) ;




FIGURE 5.3 – Images de grains segmentées avec des croix de couleur bleu, cyan et rouge, correspondant à des indices de confiance respectivement sûr, bon ou mauvais.

— une barre LEDs UV (405 nm).

Ce matériel a été installé dans l'enceinte d'acquisition de façon à pouvoir utiliser les trois illuminants sans que cela ne nécessite de montage/démontage. La caméra couleur a été remplacée pour les tests par la caméra monochrome. L'éclairage par LEDs blanches est resté installé, l'éclairage annulaire LEDs NIR a été mis en place autour de l'objectif de la caméra et la barre LEDs UV a été placée au plus proche de la caméra afin d'être centrée au dessus de la zone d'acquisition. La figure 5.4 présente la mise place des différents éléments dans l'enceinte d'acquisition. Ce montage permet de réaliser l'acquisition de trois images : NIR, UV et visible. Ces images peuvent être enregistrées en quelques secondes, le temps de basculer entre les modes d'éclairage. Cela présente l'intérêt d'obtenir des images de produits identiques, prises par la même caméra, sous des illuminants




FIGURE 5.4 – Système d’acquisition avec éclairages NIR et UV (5.4a), composé d’une barre LEDs UV (5.4c) et d’un éclairage annulaire LEDs NIR (5.4b).




FIGURE 5.5 – Images d’un mélange de grains : image NIR (5.5a), image visible (5.5b) et image UV (5.5c).

différents. Des exemples d’images sont présentés en figure 5.5. Les grains de différentes natures, proches d’un point de vue radiométrique sur l’image enregistrée dans le domaine visible, présentent des différences marquées dans les domaines NIR et UV.

5.2.2 Résultats

Les images obtenues sous les trois illuminants présentent beaucoup de différences, en particulier les images acquises dans le proche infrarouge, à 850 nm. À cette longueur d’onde, les caractéristiques de réflectance de certains produits agroalimentaires peuvent s’avérer très utiles pour faciliter la détection des objets.

La figure 5.6 présente des images de noisettes. Sur les images visible et UV, on visualise bien la présence partielle de pellicule brune sur certains objets. Cette pellicule rend ces objets difficiles à détecter sur des images visible ou UV, mais elle est n’est pas perçue sur les images NIR. L’apprentissage de modèles de forme et la méthode de détection déterministe ont été respectivement appliqués sur les images NIR d’objets isolés (figure 5.6a) et d’amas (figure 5.6b). Les résultats de la détection sont bons, et ils peuvent être appliqués sur les images visible et UV (figures 5.6d, 5.6f), sur lesquelles il

aurait été difficile de réaliser la détection.

La figure 5.7 présente des résultats obtenus par la même approche sur des grains de blé.

L'exploration des domaines proche infrarouge et ultraviolet sur des produits agroalimentaires mettent en avant l'intérêt du proche infrarouge. La surface des objets dans la bande de longueur d'ondes testée (850 nm) apparaît visuellement particulièrement homogène, alors qu'elle peut être fortement contrastée dans le visible ou l'ultraviolet, rendant dans ce cas la détection difficile. L'utilisation des méthodes d'apprentissage de modèles de forme et de détection sur les images NIR fournit d'excellents résultats, qui sont applicables aux images visible et UV de part l'architecture du système d'acquisition (mono capteur pour les trois domaines).




FIGURE 5.6 – Images de noisettes : images NIR (5.6a, 5.6b), images visible (5.6c, 5.6d) et images UV (5.6e, 5.6f).




FIGURE 5.7 – Images de blé : images NIR (5.7a, 5.7b), images visible (5.7c, 5.7d) et images UV (5.7e, 5.7f).

Chapitre 6

Conclusion

6.1 Conclusion générale

Les travaux menés durant cette thèse ont permis de mettre au point un système capable d'extraire les données nécessaires à l'inspection visuelle, tel que demandé par l'industriel.

Un système d'acquisition a été mis au point en exploitant l'enceinte d'acquisition préexistante. Des modifications matérielles ont été apportées, permettant d'une part, d'adapter les équipements de cette enceinte à notre problématique, et d'autre part, de bénéficier des avancées technologiques sur le marché de ces équipements en constante évolution. Les dispositifs d'éclairage et d'acquisition ont été remplacés, des LEDs et une nouvelle caméra ont été installées. Les LEDs présentent de nombreux avantages : spectre continu sur le domaine visible, absence de temps de chauffe et faible consommation. La nouvelle caméra, équipée d'un capteur de 5 mégapixel et d'une focale fixe, fournit des images qui sont traitées par une méthode visant à optimiser leur qualité, en atténuant notamment les phénomènes émanant de différents types de bruit par moyennage de plusieurs images acquises successivement. Une méthode d'étalonnage colorimétrique du système a également été implémentée afin d'optimiser la répétabilité des acquisitions.

Une étape d'apprentissage de modèles de forme a été mise au point. Cette étape permet au système de définir le type de forme des grains étudiés et d'en extraire les caractéristiques qui permettront d'établir les différentes classes dans le cadre d'une application donnée. Cette étape repose sur l'acquisition d'une image particulière : un opérateur détermine un échantillon d'objets représentatifs des différentes classes qu'ils souhaitent définir, le dispose dans l'enceinte d'acquisition de façon à ce que tous les objets soient isolés les uns des autres. Une forme moyenne des objets est alors construite, basée sur cette image d'objets isolés. Depuis cette forme moyenne, différents modèles de forme sont obtenus par apprentissage de paramètres propres au type de modélisation retenue. Cette modélisation peut être réalisée en considérant des modèles d'ellipses, de superellipses ou les descripteurs de Fourier. Cette étape d'apprentissage de modèles de forme est réalisée

une seule fois par application, les paramètres qui en résultent sont enregistrés et seront exploités lors de toutes les demandes de détection sur cette application.

Deux approches de détection ont été conçues pour segmenter les grains de céréales dans une image. Ces méthodes, déterministe et probabiliste, sont basées sur l'utilisation d'outils communs, mis au point pour fournir une approximation sur la localisation et le positionnement des objets. Les modèles de forme obtenus durant la phase d'apprentissage sont utilisés ; le positionnement des formes détectées est ensuite amélioré par la même méthode de contour actif avec a priori de forme pour obtenir les frontières précises d'un objet depuis une approximation. Les résultats fournis par les deux méthodes ont été évalués et comparés. L'approche probabiliste fournit cependant des résultats qui peuvent varier : ils peuvent être meilleurs ou moins bons que ceux fournis par l'approche déterministe. L'industriel privilégiera l'utilisation de l'approche déterministe pour son caractère répétable.

Les données extraites sont destinées à être exploitées pour traiter la classification des objets. Quelques exemples sont présentés : proportion de grains cassés et de grains entiers, classification selon des critères de couleur. Un prototype de système d'acquisition permettant d'accéder aux domaines proche infrarouge et ultra-violet a été mis conçu. Les images obtenues et leur traitement par les outils de détection ont permis de mettre en avant l'intérêt du proche infrarouge notamment : sur certains types de produits agroalimentaires, il permet d'obtenir une information favorisant la détection des objets. La mise en place d'un dispositif combinant plusieurs domaines de longueurs d'onde apparaît pertinente.

6.2 Axes d'amélioration

Malgré la satisfaction de l'industriel quant aux travaux menés durant cette thèse, nous pouvons établir certaines remarques ainsi que des axes d'améliorations.

Dispositif d'acquisition. En ce qui concerne le système d'acquisition, il pourrait être réellement intéressant d'envisager l'utilisation d'une caméra tri-CCD. L'utilisation d'un tel matériel pourrait en effet améliorer la qualité des acquisitions et des données colorimétriques qui en sont extraites. Le coût, toujours élevé, de ce type d'appareil demeure un frein pour les industriels, à l'heure où les capteurs plus classiques ont inondé le marché à des prix toujours plus concurrentiels.

Le processus d'acquisition tel qu'il est présenté dans ce manuscrit ne prend pas en compte l'aspect double face des grains de céréales : une seule image par échantillon est considérée. Cela est acceptable sur des applications telles que la distribution des tailles de grains, mais pas pour la recherche de défauts tels que des tâches sur le grain. Il conviendrait de prendre en compte plusieurs images pour un même échantillon, en demandant




FIGURE 6.1 – Images de reconstruction 3D d'un grain d'orge obtenues par stéréophotométrie.

à l'opérateur de mélanger les grains. Le nombre de vues nécessaires est dans ce cas un paramètre important à déterminer. L'acquisition et la détection fonctionneraient de la même manière, mais une étape de fusion des données de l'échantillon est à définir.

Détection. Les méthodes de détection, déterministe et probabiliste, fournissent de bons résultats. Cependant, nous avons pu constater que certaines modifications pourraient améliorer encore les résultats. Par exemple, telles qu'elles sont définies dans ces méthodes, les frontières d'un objet lui sont propres, c'est-à-dire que les pixels qui appartiennent à sa frontière appartiennent à l'objet. Or, tels que nos outils sont définis, un pixel ne peut appartenir à deux objets, cette notion de frontière pourrait être améliorée. Une approche subpixelique permettrait d'améliorer cet aspect, ainsi que la caractérisation générale d'un objet. Cette approche est néanmoins plus coûteuse en temps de calcul et son implémentation est moins directe.

Un autre axe d'amélioration pourrait être l'inspection d'objets de formes plus complexes ou d'échantillons composites. Pour traiter des formes plus complexes, des cerneaux de noix par exemple, il faut les modéliser : les descripteurs de Fourier pourraient a priori être utilisés. Pour traiter des échantillons composites, comme des mélanges de grains ou encore une macédoine de légumes, cela ne présente pas de difficultés particulières, mais il apparaît nécessaire de réaliser plusieurs passes de détection, avec des formes différentes.

Acquisition 3D. La mise en place d'un système d'acquisition de données 3D et l'exploitation de la disparité ou de la profondeur pourraient vraisemblablement faciliter la détection des objets. La difficulté provient de la taille des objets, en particulier leur hauteur (entre 2 et 3 millimètres pour un grain de riz), qui nécessite une résolution importante. Une approche par stéréovision a été explorée. Cependant, la résolution en profondeur demandée n'est pas compatible avec les capteurs et optiques intégrés dans le système actuellement, il faudrait considérer des composants haut de gamme pour prétendre atteindre cette résolution.




FIGURE 6.2 – Images de reconstruction 3D d’un cerneau de noix et image de reconstruction 3D en couleur (à droite), obtenues par stéréophotométrie.

Une seconde méthode a été testée : la stéréophotométrie [48, 59]. Cette approche permet d’obtenir des données 3D depuis un seul capteur, mais en considérant différentes sources d’éclairage. Une image est enregistrée pour chaque source de lumière, les données 3D sont alors obtenues en étudiant les différentes variations au niveau de la réflectance des objets illuminés. La reconstruction est facilitée lorsque les sources sont nombreuses et précisément localisées. Des acquisitions ont été réalisées sur un système de test avec la collaboration de membres de l’équipe Vortex de l’Institut de Recherche en Informatique de Toulouse (IRIT). Les figures 6.1 et 6.2 présentent les résultats obtenus en reconstruction 3D par stéréophotométrie pour un grain d’orge (figure 6.1) et un cerneau de noix (figure 6.2). La résolution de profondeur est intéressante, on distingue bien l’objet par rapport au fond, tout comme les variations d’épaisseur et même certains détails plus fins. De telles données pourraient être utiles à la détection des grains, facilitant la recherche des frontières entre les grains en s’intéressant aux zones dont l’altitude est proche de celle du fond. Par ailleurs, l’éclairage par LEDs blanches retenu dans le système d’acquisition peut être facilement commandé pour envoyer de brèves impulsions de type trigger. La mise en place d’une approche de stéréophotométrie constitue donc un axe d’amélioration à explorer, le temps de calcul de la reconstruction 3D pour un échantillon comprenant plusieurs dizaines de grains restant à déterminer.

6.3 Publications

Les travaux menés dans le cadre de cette thèse et présentés dans ce manuscrit ont donné lieu à la publication de trois articles de conférence [15, 16, 17] et un article de journal [18] :

P. Dubosclard, S. Larnier, H. Konik, A. Herbulot, and M. Devy. Automatic method for visual grading of seed food products. In *International Conference on Image Analysis and Recognition (ICIAR)*, volume 1 of *Lecture Notes in Computer Science*, pages 485–495, 2014 ;

P. Dubosclard, S. Larnier, H. Konik, A. Herbulot, and M. Devy. Automated visual grading of grain kernels by machine vision. In *The International Conference on Quality Control by Artificial Vision 2015*, pages 95340H–95340H. International Society for Optics and Photonics, 2015 ;

P. Dubosclard, S. Larnier, H. Konik, A. Herbulot, and M. Devy. Deterministic method for automatic visual grading of seed food products. In *Proceedings of the International Conference on Pattern Recognition Applications and Methods*, pages 212–217, 2015 ;

P. Dubosclard, S. Larnier, H. Konik, A. Herbulot, and M. Devy. Automatic visual grading of grain products by machine vision. *Journal of Electronic Imaging*, Accepted, To Appear.

Annexe A

Annexes

A.1 Rapport d'évaluation de la bibliothèque mise à disposition de l'entreprise



Rapport d'essai

Evaluation de l'outil de Segmentation d'image

Rapport d'essai	Ir03a v02
Instruments utilisés	Iris VA400
Réalisé pour	Alpha MOS
Date(s)	v02 – 23/01/14 (3 jours)
Auteur	H. Lechat



SOMMAIRE

I.	OBJECTIFS.....	3
II.	UTILITAIRE	3
II.1.	CONTENU DE L'UTILITAIRE	3
II.2.	PARAMETRES DE L'UTILITAIRE	3
II.3.	FICHER RESULTATS.....	4
III.	ESSAIS	5
III.1.	RIZ	5
III.2.	BLE.....	8
III.3.	GRAINS DE CIRE	12
III.4.	GRAINS D'ORGE	13
III.5.	POIS	13
III.6.	OVALES BLANCS.....	15
III.7.	GRAINS DE CORIANDRE	16
IV.	CONCLUSION	19

I. Objectifs

L'œil électronique Iris a été développé pour analyser les couleurs et les formes d'échantillons de types très divers. Cependant, pour l'analyse des formes d'objets individuels d'une image, il est nécessaire de séparer physiquement les objets sur les prises de vue, ce qui est très contraignant et qui prend beaucoup de temps pour l'utilisateur.

Un projet d'analyse d'image a été initié pour séparer informatiquement les objets d'une image où ils sont contigus. Ce projet a été développé par Pierre Dubosclard dans le cadre d'un travail de thèse en collaboration avec le LAAS.

Ce projet a abouti à la création d'une première version de logiciel de traitement d'image sous la forme d'un programme autonome de fragmentation. Une première version a été testée (cf. rapport Ir03a v01), une seconde version a été créée.

L'objectif de ces essais est d'évaluer les performances de cette 2nde version d'utilitaire et de faire des propositions d'amélioration.

II. Utilitaire

II.1. Contenu de l'utilitaire

Comme dans la première version, le programme de segmentation est contenu dans le fichier « DeterministApproach » (Figure 1). Ce programme peut soit réaliser l'apprentissage des formes d'un fichier image d'objet séparés soit réaliser l'analyse des formes d'une image à fragmentée, en fonction des paramètres du fichier « Seeds_App_Parameters ».

Data	01/12/2014 14:35	Document de fichiers	
DeterministApproach	01/12/2014 16:06	Application	949 Ko
DeterministApproach.pdb	01/12/2014 16:06	Fichier PDB	2763 Ko
libfftw3-3	15/03/2014 10:26	Fichier DLL	2177 Ko
libpng16	17/11/2014 18:28	Fichier DLL	192 Ko
opencv_core248	26/03/2014 14:24	Fichier DLL	2050 Ko
opencv_highgui248	26/03/2014 14:25	Fichier DLL	2032 Ko
opencv_imgproc248	26/03/2014 14:24	Fichier DLL	1864 Ko
PijTestSegmentation	18/11/2014 16:58	Application	48 Ko
Seeds_App_Parameters	01/12/2014 17:27	Document texte	1 Ko

Figure 1. Liste des fichiers de l'utilitaire de segmentation

II.2. Paramètres de l'utilitaire

Le programme a été paramétré pour traiter un fichier nommé « Ref.png » ou « Ref.bmp » pour l'apprentissage et « Ana.png » ou « Ana.bmp » pour l'analyse d'image (Figure 2).

```

Mode(0 : Learning // 1 : Detection)
1
*****
LEARNING
<<Input image for learning:
Data/Ref.png
<<Input mode learning (0:Meanshape Masks // 1:Meanshape equations // 2:Tocome)
1
<<Input Meanshape parameters: numbers and limits(nbr min_val max_val)
0 0 0
<<Input folder to save masks
Data/
>>Output image:
Data/RefOut.bmp
>>Output learning file:
Data/Learn.txt
>>Output objects parameters:
Data/Ref.txt
*****
DETECTION
<<Input image for detection:
Data/Ana.png
<<Input learning file:
Data/Learn.txt
<<Input theta step
18
>>Output image segmented:
Data/Ana_Out.bmp
>>Output objects parameters:
Data/Ana.txt
<<Input Mode (0:Deterministe, 1:Probabiliste)
0

```

Figure 2. Paramètres d'apprentissage de segmentation dans fichier texte

II.3. Fichier résultats

Les résultats d'analyse de forme sont exportés sous forme de fichier texte qui peut être analysé par Excel (Tableau 1). Certaines variables sont explicites :

- CoordX : Coordonnée X du centre de l'objet dans l'image (en pixels)
- CoordY : Coordonnée Y du centre de l'objet dans l'image (en pixels)
- iAxeSmallFitEll : largeur de l'ellipse (en pixel)
- iAxeBigFitEll : longueur de l'ellipse (en pixel)
- iPerimeter : périmètre de l'objet (en pixels)
- dAngle : angle de l'objet
- dRoundness : quelle formule de calcul ?

Les autres variables ne sont pas claires. Il faudrait les définir.

Proposition 1. Fournir une définition (incluant les formules mathématique) de chacune des variables des fichiers résultats

Tableau 1. Exemple de fiche de résultats d'analyse de forme

Number	CoordX	CoordY	iAxeSmallFitEll	iAxeBigFitEll	iPerimeter	dAngle	dArea	dRoundness	iAxeBigRect	iAxeSmallRect	dAreaRect	dNa	dNb	dAxiality	dOvalCoef
4	132.82	418.84	8	39	89	114.679	267	0.423585	41	26	1066	0	0	0	0
53	141.788	269.656	11	46	105	169.39	419	0.477579	49	22	1078	0	0	0	0
54	151.658	266.478	9	46	94	169.139	314	0.446564	43	20	860	0	0	0	0
50	159.966	358.885	10	45	101	53.5835	353	0.434852	44	35	1540	0	0	0	0
55	161.117	374.484	10	43	102	37.1703	350	0.422744	46	36	1656	0	0	0	0
62	173.771	374.308	10	44	99	30.7517	347.5	0.445547	43	33	1419	0	0	0	0
15	179.803	286.952	10	43	94	145.749	329.5	0.468607	43	33	1419	0	0	0	0
63	181.911	380.358	9	44	96	24.0509	306	0.417242	43	29	1247	0	0	0	0



III. Essais

III.1. Riz

Des essais de segmentation ont été réalisés sur des images de riz prises sur fond noir avec l'Iris VA300 avec un zoom (Figure 3).



Figure 3. Image de l'essai 1 sur des grains de riz

L'apprentissage ne prend pas en compte tous les objets, notamment les grains de riz cassés alors que ceux-ci sont censés être représentatifs de la population analysée (Figure 3). L'analyse de segmentation de l'image des grains collés a montré 6% défauts de reconnaissance répartis comme suit :

- un seul grain oublié (a) soit 1%
- 4 grains présentant un ergot (b) soit 4%
- 1 grain coupé (c, la taille du grain voisin est surestimée)

Le fichier résultat montre bien la présence de 99 grains sur les 100. L'analyse de ce fichier résultat montre des tailles de grains qui semblent légèrement inférieures à leur taille réelle. Il est possible que l'épaisseur du trait de contour (1 pixel) ne soit pas prise en compte.




Figure 4. Évaluation de la taille de certains grains par le fichier créé

L'analyse d'une autre image a montré un taux d'erreur de 3% avec un grain oublié qui semble systématique (Figure 5).




Figure 5. Essai 2 Segmentation du riz

L'analyse d'une autre image a montré un taux d'erreur de 3% avec un grain oublié qui semble systématique (Figure 5).




Figure 6. Essai 3 Segmentation du riz

Dans l'analyse de l'image la plus encombrée (Figure 7), le taux d'erreur est le plus important (environ 15%):



- 2% de grains avec ergot (b)
- 5% de grains mal distingués (c)
- 8% de grains de surface sous-estimée (d)




Figure 7. Essai 4 Segmentation du riz

L'essai 5 a nécessité 5'40 de calcul (Figure 8). Le taux de défaut a été estimé à 9% :

- Un grand manquant (a)
- 2 grains à ergots (b)
- 2 grains mal détournés (c)
- 4 grains de taille sous-estimée (d)




Figure 8. Essai 5 Segmentation du riz

Le taux d'erreur est d'autant plus grand lorsque les grains sont les plus rapprochés (Tableau 2). Le nombre de grains cassés (au maximum ¼ de la taille standard) dans l'échantillon a été estimé à 11. Le nombre de grains présentant une longueur inférieure ou égale à 35 pixels est très proche de cette valeur dans tous les cas. Les cas d'excès sont liés à des erreurs de reconnaissance de type c.

Tableau 2. Fréquence des erreurs sur les grains de riz pour les différents essais

Essai	Essai 1	Essai 2	Essai 3	Essai 4	Essai 5	Réel
n (%)	99	99	99	99	98	100
grains cassés	12	12	11	11	12	11
grain oublié (a)	1	1	1	0	1	-
ergot (b)	4	2	2	2	2	0
grain mal identifié ©	1			5	2	-
Aire sous-estimée (d)	-			8	4	-

L'analyse statistique des données des 5 images du même échantillon de riz analysées ont montré une variabilité d'environ 10% dans les fréquences de taille (Figure 9). La plus forte variabilité est observée sur l'échantillon le plus compact.




Figure 9. Analyse de la répartition par taille des grains des différentes images du même échantillon de riz

Proposition 2. Vérifier qu'il n'y a pas systématiquement oublié d'un objet dans le programme, si c'est le cas, chercher à le corriger

Proposition 3. Créer une version de programme sans affichage pour diminuer le temps de calcul (garder une version avec pour pouvoir analyser les problèmes éventuels)

Proposition 4. Améliorer la reconnaissance de l'intégralité des grains qui est une des causes des erreurs de type d et b.

III.2. Blé

Des essais de segmentation ont aussi été réalisés sur des images de 100 grains de blé prises sur fond noir (Figure 10). Cependant, comme dans la première version du logiciel, le traitement de l'image utilisé pour l'apprentissage n'est pas adapté ; une grande proportion de grain est sous-estimée.

La mise en place d'un programme de seuillage automatique est trop ambitieuse pour ce projet et visiblement inapproprié surtout dans la mesure où l'arrière-plan sera plus souvent blanc que noir.




Figure 10. Apprentissage de l'image de référence sur image non seuillée de blé

En utilisant une image déjà seuillée comme image d'apprentissage la reconnaissance des grains est meilleure dans cette phase (Figure 11).




Figure 11. Apprentissage de l'image de référence sur image seuillée de blé

L'image d'apprentissage seuillée a été analysée avec les critères obtenus (Figure 12). Environ 6% de taux d'erreur (uniquement sous-estimation de surface de grain) a été obtenu.




Figure 12. Apprentissage de l'image de référence sur image seuillée de blé

L'analyse de l'image seuillée de Blé 2 (Figure 13) a duré 5'50 et a montré un taux d'erreur d'environ 7% (dont 6% de surface sous estimée)




Figure 13. Apprentissage de l'image de référence sur image seuillée de blé 2

L'analyse de l'image Blé3 seuillée a pris environ 4 min et montré un taux d'erreur de 7% environ (Figure 14).




Figure 14. Apprentissage de l'image de référence sur image seuillée de blé 3

Sur l'image blé4, le même taux d'erreur est observé (Figure 15). Les grains, dont la surface a été sous-estimée, semblent correspondre aux grains qui n'ont pas été pris en compte dans l'apprentissage.




Figure 15. Apprentissage de l'image de référence sur image seuillée de blé 4




Figure 16. Apprentissage de l'image de référence sur image seuillée de blé 5

L'analyse des données collectées dans ces 5 images d'un même échantillon de blé a montré une certaine variabilité dans les longueurs et dans les aires qui peut être en grande partie attribuable aux défauts de sous-estimation d'aire de certains grains (Figure 17). L'incertitude sur ces fréquences a été estimée à 10%.




Figure 17. Analyse de la répartition par taille des grains des différentes images du même échantillon de blé (images seuillées)

L'analyse des images seuillées a permis de retrouver le nombre exact de grains dans chacune des images (Tableau 3). Les erreurs correspondent à des aires sous-estimées qui pourraient être liées à la non prise en compte des gros grains dans la phase d'apprentissage.

Tableau 3. Tableau récapitulatif des comptages de grains de blé dans les différentes images seuillées et le taux d'erreur

Essai	Essai 1	Essai 2	Essai 3	Essai 4	Essai 5	Réel
n (%)	100	100	100	100	100	100
grain oublié (a)	0	0	0	0	0	0
ergot (b)	0	0	0	0	0	0
grain mal identifié ©	0	1	0	0	0	0
Aire sous-estimée (d)	6	6	7	8	7	-

Proposition 5. Exclure le seuillage automatique du programme de segmentation (celui-ci sera pris en compte par Alpha Soft de manière plus efficace)

Proposition 6. Inclure dans l'apprentissage tous les objets isolés (même s'ils sont collés, c'est à l'utilisateur de s'assurer qu'il n'y en a pas)

III.3. Grains de cire

Des essais de segmentation ont été réalisés sur des images de 100 grains de cire prises sur fond noir (Figure 18). Le seuillage est correct ; l'analyse peut être réalisée sur l'image brute.




Figure 18. Images d'apprentissage de 100 grains de cire

L'analyse de l'image utilisée pour l'apprentissage montre un taux de défaut de 8% dont 1 grain oublié (a) et 7 d'aire sous-estimée (Figure 19). 99 grains sur 100 ont été identifiés.




Figure 19. Segmentation des images de 100 grains de cire 1

L'image de cire 2 n'a pas pu être analysée, l'analyse boucle sans fin et a dû être arrêtée après 30 min d'analyse (Figure 20).




Figure 20. Segmentation des images de 100 grains de cire 2

III.4. Grains d'orge

L'analyse des grains d'orge a entraîné des boucles de calcul sans fin.

III.5. Pois

L'analyse des images de pois a aussi montré des problèmes de seuillage (Figure 21).




Figure 21. Images d'apprentissage non seuillée de pois

L'apprentissage a été réalisé sur l'image de référence seuillée (Figure 22). L'analyse a montré un taux de défaut de 8% au moins mais tous les grains ont été détectés (Figure 23).




Figure 22. Images d'apprentissage seuillée de pois




Figure 23. Segmentation des images de pois 1

L'analyse de l'image de pois 2 montre le même taux d'erreur et de reconnaissance (Figure 24).




Figure 24. Segmentation des images de pois 2

L'image de pois présentant un taux de contact important montre aussi un taux de reconnaissance de 100% et un taux d'erreur de 7% (Figure 25).




Figure 25. Segmentation des images de pois 3

Le taux d'erreur a été estimé à 10% sur les images de pois4 (Figure 26) et 5 (Figure 27).




Figure 26. Segmentation des images de pois 4




Figure 27. Segmentation des images de pois 5

III.6. Ovaies blancs

L'apprentissage a aussi été réalisé sur des formes artificielles avec succès (Figure 28). L'analyse d'une image d'essai a bouclé sans fin après reconnaissance de 16 ellipses sur 20 (Figure 29). Ce blocage semble se produire sur les parties ou les chevauchements de grain ont entraîné leur grignotage. Les grains trop grignotés sont alors difficiles à reconnaître.




Figure 28. Image d'apprentissage des ovaies blancs




Figure 29. Image de test des ovales blancs (bloqué)

III.7. Grains de coriandre

Des nouvelles images ont été prises avec le système IRIS VA400 avec une définition 800 x 600. L'analyse des images de coriandre a montré des problèmes de seuillage (Figure 21).




Figure 30. Analyse de l'image de coriandre (non seuillée) utilisée pour l'apprentissage

Avec des images préalablement seuillées avec AlphaSoft, les résultats sont bien meilleurs (Figure 31). 100% des grains ont été comptés et un taux d'erreur de 3% a été estimé (aire sous-estimée).




Figure 31. Segmentation des images de coriandre 1 (seuillée et aussi utilisée comme référence)

L'analyse d'une 2^{ème} image seuillée n'a permis d'identifier que 98 grains sur les 100 et 2 grains d'aire sous-estimée (Figure 32).




Figure 32. Segmentation des images de coriandre 2 (seuillée et aussi utilisée comme référence)

Sur les autres images, le taux d'erreur est faible mais des grains sombres et de petite taille ont été oubliés.

Des analyses ont aussi été réalisées sur fond blanc (Figure 33). Cependant, le seuillage élimine les grains et garde le fond. Le programme de seuillage est donc inapproprié.




Figure 33. Apprentissage d'images réalisées sur fond blanc

Les mêmes images ont été analysées après seuillage sur AlphaSoft (Figure 34). L'analyse de l'image de référence exclue certains grains de manière peu compréhensible.




Figure 34. Apprentissage d'images de Coriandre réalisées sur fond blanc et seuillée avant analyse

L'analyse des images de référence et de la coriandre 2 ont permis d'identifier tous les grains avec un taux d'erreur de 4% sur l'aire (Figure 35).




Figure 35. Apprentissage d'images de Coriandre 1 réalisées sur fond blanc et seuillée avant analyse




Figure 36. Apprentissage d'images de Coriandre 2 réalisées sur fond blanc et seuillée avant analyse

Sur les images de grains très rapprochés, le taux d'erreur est plus important (12% environ) et les grains apparaissent très déformés mais leur nombre est bien déterminé. Cependant, dans ce cas le manque de définition des grains peut être en cause.




Figure 37. Apprentissage d'images de Coriandre 3 réalisées sur fond blanc et seuillée avant analyse

Dans les images présentant des impuretés de plus grande taille (Figure 38). Le taux d'erreur est trop important. Les baies de genièvres ont été divisées en 3, 4 ou 5 selon leur taille.




Figure 38. Apprentissage d'images de Coriandre 4 réalisées sur fond blanc et seuillée avant analyse

IV. Conclusion

L'outil de fragmentation d'image a été bien amélioré par rapport à la première version. Le nombre de grains de différents types (blé, riz, cire, pois, coriandre) est bien calculé. En revanche, il est plus difficile pour les grains d'orge.

L'analyse des images montre parfois un ou 2 grains oubliés, ce qui peut être lié à un seuil mal paramétré. Cependant ce taux d'erreur est tout à fait acceptable pour les applications envisagées.

La plus grande proportion d'erreur provient de grains bien détectés mais dont la surface n'a pas été toute prise en compte. Il serait souhaitable de diminuer cette proportion d'erreur pour atteindre 1 ou 2%. L'utilisation de tous les grains de l'image d'apprentissage pour faire des statistiques de formes pourrait permettre de fixer des limites plus larges que celles qui sont fixées actuellement.

Par ailleurs, le seuillage automatique n'est vraiment pas au point. Il serait préférable de le supprimer de l'outil pour se concentrer sur les images déjà seuillées sur Alpha Soft (ou utilisant les paramètres de seuillage réglés dans AlphaSoft).

Maintenant que les performances de reconnaissance des grains deviennent satisfaisantes, il serait souhaitable d'améliorer la vitesse de calcul. En effet, le traitement de chaque image prend entre 2 et 6 minutes (si ce n'est plus en cas de boucle sans fin).

Ainsi, un certain nombre de propositions ont été faites :

- Proposition 1. Fournir une définition (incluant les formules mathématique) de chacune des variables des fichiers résultats..... 4
- Proposition 2. Vérifier qu'il n'y a pas systématiquement oubli d'un objet dans le programme, si c'est le cas chercher à le corriger..... 8
- Proposition 3. Créer une version de programme sans affichage pour diminuer le temps de calcul (garder une version avec pour pouvoir analyser les problèmes éventuels) 8
- Proposition 4. Améliorer la reconnaissance de l'intégralité des grains qui est une des causes des erreurs de type d et b..... 8
- Proposition 5. Exclure le seuillage automatique du programme de segmentation (celui-ci sera pris en compte par Alpha Soft de manière plus efficace)..... 11
- Proposition 6. Inclure dans l'apprentissage tous les objets isolé (même s'ils sont collés, c'est à l'utilisateur de s'assurer qu'il n'y en a pas)..... 11



Table des figures

1.1	Système d'analyse visuelle.	9
1.2	Deux exemples d'images complexes de grains d'orge (1.2a) et de riz (1.2b).	10
2.1	Exemples de cabines à lumière.	17
2.2	DigiEye Verivide.	17
2.3	Système d'acquisition des images IRIS.	18
2.4	Disposition de la caméra et de son optique.	19
2.5	Brique de 4 LEDs blanches.	19
2.6	Répartition spectrale des LED blanches.	20
2.7	Plaques inférieure (gauche) et supérieure (droite).	20
2.8	Image utilisée pour le calcul de distorsion.	22
2.9	Luxmètre Testo 540 utilisé pour les mesures d'homogénéité d'éclairage.	23
2.10	Images de mesures de l'homogénéité de l'éclairage en différents points de la zone d'acquisition (2.10a) et mesures associées (2.10b), les valeurs sont en pourcentage relatifs par rapport à la valeur maximum.	24
2.11	Évolution de l'éclairement lumineux des LEDs blanches.	25
2.12	Évolution de l'éclairement lumineux de tubes fluorescents.	26
2.13	Image de 24 formes circulaires identiques.	26
2.14	Affichage graphique de l'évolution d'une zone de pixels en fonction du nombre d'images moyennées : de une (D(1)) à dix (D(10)) acquisitions.	28
2.15	Zoom sur l'image brute (M(1)) et moyenne sur 6 images (M(6)), ainsi que leurs représentation graphique (D(1) et D(6)), et image moyenne de 10 images filtrées par un filtre médian de taille 3×3 (M(median(10))) utilisée comme référence.	29
2.16	Influence du nombre d'images pour le calcul d'une image moyenne.	30
2.17	Couleurs 8, 14, 15 et 16 de la charte extraites depuis l'image brute (à gauche) et depuis l'image moyennée (à droite), telles qu'elles sont utilisées lors de l'étalonnage radiométrique.	31
2.18	Charte 24 couleurs X-Rite ColorChecker® Classic	32
2.19	X-Rite Colorchecker® Classic, focale 5mm : plateau blanc (a) et plateau noir (b). X-Rite Colorchecker® Passport, focale 12mm : plateau noir (c).	32
2.20	Illustration de l'assistant d'étalonnage radiométrique intégré dans le logiciel.	34
2.21	Mesures sur 60 minutes.	34

2.22	Mesures sur 3 jours.	34
2.23	Évolution de la distance couleur ΔE_{76} par rapport à la mesure initiale $t=0$	35
2.24	Résultat d'étalonnage sur deux systèmes différents : système A à gauche, système B à droite.	35
3.1	Images de grains isolés utilisées pour l'apprentissage de modèles de forme.	38
3.2	Image de fond seul (3.2a), image d'objets (3.2b, 3.2d) et image après séparation des objets et du fond (3.2c, 3.2e).	39
3.3	Image de fond seul, image d'objets et image après séparation des objets et du fond.	40
3.4	Image de 100 grains de riz isolés (3.4a), image binaire avec objets et fond séparés par la méthode d'Otsu (3.4b).	40
3.5	6 formes artificielles avec de gauche à droite : étoile 1 (ET1), éclair (EC) et étoile 2 (ET2) sur la première ligne; étoile 1 avec changement d'échelle (ET1 _S), étoile 1 avec rotation (ET1 _R) et étoile 1 avec changement d'échelle et rotation (ET1 _R _S) sur la seconde ligne.	43
3.6	Image artificielle d'un objet dont les descripteurs de Fourier sont présentés en figure 3.7.	45
3.7	Haut : coordonnées du contour de l'objet présenté en figure 3.6; bas : descripteurs de Fourier associés au contour.	45
3.8	Image d'apprentissage de modèles de forme binarisée : 100 grains de blé sont séparés du fond.	46
3.9	Image de transformée en distance euclidienne avec un voisinage 8.	46
3.10	Zooms sur 6 objets de l'image de transformée en distance avec en bleu le repère autour du centre de l'objet.	47
3.11	Redressement d'un objet depuis l'information d'orientation obtenue par les descripteurs de Fourier	48
3.12	Processus de construction de l'image moyenne de l'objet.	49
3.13	Forme moyenne obtenue pour des grains d'orge (3.13a), histogramme de la répartition des grains sur cette forme (3.13b) et modèles de forme obtenus en considérant les maxima locaux de l'histogramme (3.13c).	49
3.14	8 superellipses obtenues en faisant varier la valeur du paramètre ϵ (de gauche à droite et de haut en bas) : 0.25, 0.6, 0.9, 1.3, 1.6, 2, 2.3, 2.65.	51
3.15	Modélisations par des ellipses (haut) et des superellipses (bas) de grains de riz (gauche) et d'orge de type 1 (milieu) et 2 (droite).	52
3.16	Zoom sur un objet depuis image originale (3.16a) et image en niveaux de gris de l'objet extrait par séparation avec le fond (3.16b).	53
3.17	Image binaire obtenue par reconstruction d'un contour en faisant varier le nombre de descripteurs de Fourier utilisés (table 3.4).	54
3.18	Schéma des différentes étapes de l'apprentissage de modèles de forme depuis une image d'objets isolés.	56

3.19	Image de forme moyenne obtenue sur des grains de blé 3.19a et modèles de forme obtenus : 3 formes ont été modélisées par des ellipses (3.19b, 3.19c et 3.19d), des superellipses (3.19e, 3.19f et 3.19g) et les descripteurs de Fourier (3.19h, 3.19i et 3.19j).	57
3.20	Image de forme moyenne obtenue sur des grains d'orge de type 1 3.20a et modèles de forme obtenus : 3 formes ont été modélisées par des ellipses (3.20b, 3.20c et 3.20d), des superellipses (3.20e, 3.20f et 3.20g) et les descripteurs de Fourier (3.20h, 3.20i et 3.20j).	58
3.21	Image de forme moyenne obtenue sur des grains d'orge de type 2 3.21a et modèles de forme obtenus : 3 formes ont été modélisées par des ellipses (3.21b, 3.21c et 3.21d), des superellipses (3.21e, 3.21f et 3.21g) et les descripteurs de Fourier (3.21h, 3.21i et 3.21j).	59
4.1	Exemples de séparation du fond et d'objets disposés en amas : orge (4.1a), riz (4.1b) et blé (4.1c).	64
4.2	De haut en bas : modèle de forme selon 5 pas d'orientations, zooms sur images de I_1 correspondantes, de I_2 et de I_3 . Ces données ont été obtenues depuis l'image présentée en figure 4.4	66
4.3	Valeurs de sorties de l'indicateurs de transformée en distance en fonction des valeurs d'entrée, m représente la valeur moyenne et E l'écart type des valeurs relevées durant l'apprentissage de modèles de forme.	68
4.4	Image de grains d'orge originale (gauche), image binaire séparant les objets du fond (milieu) et image de l'indicateur I_4 de transformée en distance.	69
4.5	Carte des minimums de l'énergie E obtenue pour une image de grains de riz.	70
4.6	Zoom sur image originale (gauche), sur carte des minimums de l'énergie E (milieu) et image d'illustration superposant les deux (droite).	71
4.7	Influence de la valeur de ρ sur la moyenne (gauche) et la médiane (droite) de l'erreur en valeur absolue.	73
4.8	Comparaison entre vérité terrain (gauche) et estimation (droite) sur un lot de grains de riz.	74
4.9	Comparaison entre vérité terrain (gauche) et estimation (droite) sur un lot de grains de blé.	74
4.10	Comparaison entre vérité terrain (gauche) et estimation (droite) sur un lot de grains d'orge de type 1.	75
4.11	Comparaison entre vérité terrain (gauche) et estimation (droite) sur un lot de grains d'orge de type 2.	75
4.12	Détails de deux mauvaises estimations de l'orientation par le tenseur de structure.	76
4.13	Détails d'une image d'amas de grains de riz et positionnement du modèle de forme à l'orientation considérée par les indicateurs pour un pas de 10 degrés (140 degrés, en vert), et à l'orientation fournie par le tenseur de structure (144.8 degrés, en bleu).	76

4.14	Image de 152×110 pixels utilisée pour déterminer les paramètres de la méthode de contour actif.	78
4.15	Exemples de résultats obtenus avec variation des paramètres de la méthode de contour actif.	78
4.16	Exemples d'images I_{F_n} (bas) utilisées pour définir le terme de frontière de la méthode de contour actif obtenue pour depuis des images en niveaux de gris (haut).	79
4.17	6 exemples de résultats obtenus à l'issue de la méthode de contour actif avec a priori de forme : les contours initiaux et finaux apparaissent respectivement en bleu et en vert.	80
4.18	Exemples d'objets non validés avec le contour initial en bleu et le contour retourné par la méthode de contour actif en rouge.	81
4.19	Position et marques d'une ellipse	83
4.20	Objet x_i et $\mathcal{F}(x_i)$ sa couronne (a), et leur équivalent discrétisé (b).	83
4.21	Diagrammes des trois étapes de la dynamique de naissances et morts multiples.	87
4.22	Diagramme de la réalisation de la méthode de segmentation déterministe.	88
4.23	Exemples d'images de vérité terrain.	89
4.24	Orge 1 E (1), orge 1 SE (2), orge 2 E (3), orge 2 SE (4), riz E (5), riz SE (6), blé E (7), blé SE (8)	91
4.25	Images de détection de grains de riz et d'orge, méthode déterministe (gauche) et probabiliste (droite).	92
4.26	Résultats de détection sur des images de grains d'orge. De haut bas : vérité terrain, méthode déterministe E et méthode déterministe SE. Les rectangles rouges situent les erreurs de détection.	93
4.27	Images de détection obtenues par la méthode déterministe (haut) et par la méthode probabiliste (bas).	94
4.28	Images d'un même échantillon de 100 grains de riz à différentes densités : grains isolés (4.28a) et haute densité (4.28b).	95
4.29	Courbes de distributions (petit axe 4.29a, grand axe 4.29b, périmètre 4.29c et aire 4.29d)des grains de riz de l'échantillon présenté en figure 4.28 pour des densités croissantes allant de 1 (4.28a) à 5(4.28b).	95
5.1	À gauche : distribution en aire des grains de riz présentés au chapitre 4 sur l'image de la figure 4.28 ; à droite : résultats sur l'image, les grains considérés cassés sont en rouge et les grains entiers en bleu.	98
5.2	À gauche : image segmentée de pois avec une lettre sur chaque objet détecté, correspondant aux classes qui ont été définies sur des critères de couleur moyenne, illustrées à droite.	99
5.3	Images de grains segmentées avec des croix de couleur bleu, cyan et rouge, correspondant à des indices de confiance respectivement sûr, bon ou mauvais.	100

5.4	Système d'acquisition avec éclairages NIR et UV (5.4a), composé d'une barre LEDs UV (5.4c) et d'un éclairage annulaire LEDs NIR (5.4b). . . .	101
5.5	Images d'un mélange de grains : image NIR (5.5a), image visible (5.5b) et image UV (5.5c).	101
5.6	Images de noisettes : images NIR (5.6a, 5.6b), images visible (5.6c, 5.6d) et images UV (5.6e, 5.6f).	103
5.7	Images de blé : images NIR (5.7a, 5.7b), images visible (5.7c, 5.7d) et images UV (5.7e, 5.7f).	104
6.1	Images de reconstruction 3D d'un grain d'orge obtenues par stéréophotométrie.	107
6.2	Images de reconstruction 3D d'un cerneau de noix et image de reconstruction 3D en couleur (à droite), obtenues par stéréophotométrie. . . .	108

Liste des tableaux

2.1	Valeurs obtenues pour le calcul de la distorsion.	22
2.2	Mesures relevées (aire, grand axe et petit axe), moyennes et écarts type des 24 formes circulaires.	27
2.3	Synthèse des tests d'étalonnage radiométrique : distance couleur ΔE_{76} moyen sur les 24 couleurs de la charte, comparaison des résultats sur 3 jours différents (J_1, J_2, J_3), à des heures différentes (H_1, H_2, H_3) et deux systèmes différents (S_A, S_B).	33
3.1	Exemples de valeurs d'attributs obtenus durant l'apprentissage de modèles de forme.	41
3.2	Valeurs des moments de Hu obtenues depuis les 6 formes de la figure 3.5.	42
3.3	Exemples de valeurs de transformée en distance obtenues durant l'apprentissage de modèles de forme.	46
3.4	Nombres de descripteurs de Fourier utilisés pour obtenir les reconstructions présentées en figure 3.17.	55
4.1	Statistiques sur l'erreur d'orientation en valeur absolue.	73
4.2	Pourcentage d'objets détectés et erreur moyenne sur les barycentres.	91

Bibliographie

- [1] A. Arefi, A. M. Motlagh, and A. Khoshroo. Recognition of weed seed species by image processing. *Journal of Food, Agriculture and Environment*, 9 :379–383, 2011.
- [2] A.H. Barr. Superquadrics and angle-preserving transformations. *IEEE Comput. Graph. Appl.*, 1(1) :11–23, January 1981.
- [3] S. Ben Hadj, F. Chatelain, X. Descombes, and J. Zerubia. Estimation des paramètres de modèles de processus ponctuels marqués pour l’extraction d’objets en imagerie spatiale et aérienne haute résolution. Research Report RR-7350, INRIA, August 2010.
- [4] Y. Benezeth, P.-M. Jodoin, B. Emile, H. Laurent, and C. Rosenberger. Review and evaluation of commonly-implemented background subtraction algorithms. In *Pattern Recognition, 2008. ICPR 2008. 19th International Conference on*, pages 1–4, Dec 2008.
- [5] G. Borgefors. Distance transformations in digital images. *Comput. Vision Graph. Image Process.*, 34(3) :344–371, June 1986.
- [6] X. Bresson, P. Vandergheynst, and J.-P. Thiran. A variational model for object segmentation using boundary information and shape prior driven by the Mumford-Shah functional. *International Journal of Computer Vision*, 68(2) :145–162, 2006.
- [7] CImg. Website. <http://cimg.eu/>. Page consultée le 01/11/2015.
- [8] TQC Colorbox. Website. <http://www.tqc.eu/en/products/article/colorbox-illuminated-assessment-cabinets>. Page consultée le 01/11/2015.
- [9] S. Descamps, X. Descombes, A. Béchet, and J. Zerubia. Détection de flamants roses par processus ponctuels marqués pour l’estimation de la taille des populations. Research Report RR-6328, 2007.
- [10] S. Descamps, X. Descombes, A. Bechet, and J. Zerubia. Automatic flamingo detection using a multiple birth and death process. In *Proc. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Las Vegas, USA, 2008.
- [11] X. Descombes. *Méthodes stochastiques en analyse d’image : des champs de Markov aux processus ponctuels marqués*. Hdr, Université Nice Sophia Antipolis, 2004.

- [12] X. Descombes, R. Minlos, and E. Zhizhina. Object extraction using a stochastic birth-and-death dynamics in continuum. *Journal of Mathematical Imaging and Vision*, 33 :136–139, 2009.
- [13] L. R. Dice. Measures of the amount of ecologic association between species. *Ecology*, 26(3) :297–302, 1945.
- [14] Verivide DigiEye. Website. <http://www.verivide.com/digieye>. Page consultée le 01/11/2015.
- [15] P. Dubosclard, S. Larnier, H. Konik, A. Herbulot, and M. Devy. Automatic method for visual grading of seed food products. In *International Conference on Image Analysis and Recognition (ICIAR)*, volume 1 of *Lecture Notes in Computer Science*, pages 485–495, 2014.
- [16] P. Dubosclard, S. Larnier, H. Konik, A. Herbulot, and M. Devy. Automated visual grading of grain kernels by machine vision. In *The International Conference on Quality Control by Artificial Vision 2015*, pages 95340H–95340H. International Society for Optics and Photonics, 2015.
- [17] P. Dubosclard, S. Larnier, H. Konik, A. Herbulot, and M. Devy. Deterministic method for automatic visual grading of seed food products. In *Proceedings of the International Conference on Pattern Recognition Applications and Methods*, pages 212–217, 2015.
- [18] P. Dubosclard, S. Larnier, H. Konik, A. Herbulot, and M. Devy. Automatic visual grading of grain products by machine vision. *Journal of Electronic Imaging*, Accepted, To Appear.
- [19] M. Faessel and F. Courtois. Touching grain kernels separation by gap-filling. *Image Analysis and Stereology*, 28(3) :195–203, 2011.
- [20] A. Fitzgibbon and R. B. Fisher. A buyer’s guide to conic fitting. In *In British Machine Vision Conference*, pages 513–522, 1995.
- [21] A. Folkers and H. Samet. Content-based image retrieval using fourier descriptors on a logo database. In *Pattern Recognition, 2002. Proceedings. 16th International Conference on*, volume 3, pages 521–524 vol.3, 2002.
- [22] M. A. Föstner and E. Gülch. A Fast Operator for Detection and Precise Location of Distinct Points, Corners and Centers of Circular Features. In *ISPRS Intercommission Workshop on Fast Processing of Photogrammetric Data*, pages 281–305, Interlaken, Switzerland, 1987.
- [23] I. Golpour, J. A. Parian, R. A. Chayjan, et al. Identification and classification of bulk paddy, brown, and white rice cultivars with colour features extraction using image analysis and neural network. *Czech Journal of Food Sciences*, 32(3) :280–287, 2014.

- [24] G.H. Golub and C. Reinsch. Singular value decomposition and least squares solutions. *Numerische Mathematik*, 14(5) :403–420, 1970.
- [25] F. Guevara-Hernandez and J. Gomez-Gil. A machine vision system for classification of wheat and barley grain kernels. *Spanish Journal of Agricultural Research*, 9(3) :672–680, 2011.
- [26] C. Harris and M. Stephens. A combined corner and edge detector. In *In Proc. of Fourth Alvey Vision Conference*, pages 147–151, 1988.
- [27] R. Hodges and G. Farrell. *Crop post-harvest : science and technology*, volume Vol 2 : Durables : case studies in the handling and storage of durable commodities. Blackwell science, 2004.
- [28] M.K. Hu. Visual pattern recognition by moment invariants. *Information Theory, IRE Transactions on*, 8(2) :179–187, 1962.
- [29] A.K. Jain. *Fundamentals of Digital Image Processing*. Prentice-Hall, Inc., Upper Saddle River, NJ, USA, 1989.
- [30] C. Lacoste, X. Descombes, and J. Zerubia. Point processes for unsupervised line network extraction in remote sensing. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(10) :1568–1579, 2005.
- [31] S. Larnier. Structure tensor based analysis of touching grain kernels for visual grading. Technical Report 15019, LAAS, 2015.
- [32] P. Lin, Y.M. Chen, Y. He, and G.W. Hu. A novel matching algorithm for splitting touching rice kernels based on contour curvature analysis. *Computers and Electronics in Agriculture*, 109 :124 – 133, 2014.
- [33] B. D. Lucas and T. Kanade. An iterative image registration technique with an application to stereo vision. pages 674–679, 1981.
- [34] R. Lukac and K. N. Plataniotis. *Color image processing : methods and applications*. Image processing series. CRC/Taylor & Francis, Boca Raton, FL, 2007.
- [35] X.Y. Luo. *Color image analysis for cereal grain classification*. PhD thesis, University of Manitoba, 1998.
- [36] H. K. Mebatsion, J. Paliwal, and D. Jayas. A novel, invariant elliptic fourier coefficient based classification of cereal grains. *Biosystems engineering*, 111(4) :422–428, 2012.
- [37] A. Meijster, J.B.T.M. Roerdink, and W.H. Hesselink. A general algorithm for computing distance transforms in linear time. In John Goutsias, Luc Vincent, and DanS. Bloomberg, editors, *Mathematical Morphology and its Applications to Image and Signal Processing*, volume 18 of *Computational Imaging and Vision*, pages 331–340. Springer US, 2000.

- [38] L.A. Mohan, C. Karunakaran, D.S. Jayas, and NDG White. Classification of bulk cereals using visible and nir reflectance characteristics. *Canadian Biosystems Engineering*, 47(7) :7–14, 2005.
- [39] Alpha MOS. Website. <http://www.alpha-mos.com/>. Page consultée le 01/11/2015.
- [40] OpenCV. Website. <http://opencv.org/>. Page consultée le 01/11/2015.
- [41] N. Otsu. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man and Cybernetics*, 9(1) :62–66, 1979.
- [42] Pantone. Website. <http://www.pantone.com/pages/Products/Product.aspx?pid=265&ca=7>. Page consultée le 01/11/2015.
- [43] A. Pentland. Automatic extraction of deformable part models. *International Journal of Computer Vision*, 4(2) :107–126, 1990.
- [44] G. Perrin, X. Descombes, and J. Zerubia. A marked point process model for tree crown extraction in plantations. In *Image Processing, 2005. ICIP 2005. IEEE International Conference on*, volume 1, pages I–661–4, Sept 2005.
- [45] K. N. Plataniotis and A. N. Venetsanopoulos. *Color Image Processing and Applications*. Springer-Verlag New York, Inc., New York, NY, USA, 2000.
- [46] N. Pousset. *Caracterisation of colour rendering of new lighting sources : Light Emitting Diodes (LED)*. Thèse, Conservatoire national des arts et métiers, Décembre 2009.
- [47] W.H. Press, B.P. Flannery, S.A. Teukolsky, and W.T. Vetterling. *Numerical Recipes in C : The Art of Scientific Computing*. Cambridge University Press, New York, NY, USA, 1988.
- [48] Y. Quéau and J-D. Durou. Some illumination models for industrial applications of photometric stereo. In *The International Conference on Quality Control by Artificial Vision 2015*, 2015.
- [49] A.R. Rao and B.G. Schunck. Computing oriented texture fields. In *Computer Vision and Pattern Recognition, 1989. Proceedings CVPR '89., IEEE Computer Society Conference on*, pages 61–68, Jun 1989.
- [50] P.L. Rosin. Fitting superellipses. *IEEE Trans. Pattern Anal. Mach. Intell.*, 22(7) :726–732, 2000.
- [51] P.L. Rosin and G.A.W. West. Curve segmentation and representation by superellipses. *IEE Proceedings - Vision, Image and Signal Processing*, 142 :280–288, October 1995.

- [52] F. Solina and R. Bajcsy. Recovery of parametric models from range images : The case for superquadrics with global deformations. *IEEE Trans. Pattern Anal. Mach. Intell.*, 12(2) :131–147, 1990.
- [53] S. Suzuki and Keiichi Abe. Topological structural analysis of digitized binary images by border following. *Computer Vision, Graphics, and Image Processing*, 30(1) :32 – 46, 1985.
- [54] A. Trémeau, C. Fernandez-Maloigne, and P. Bonton. *Image numérique couleur. De l'acquisition au traitement*. Dunod, 2004. Parmi les auteurs et contributeurs : S. Philipp-Foliguet, M. Cord.
- [55] J. Vandenhirtz. Automated classification of seeds and quality assessment of crop seeds with the lemnatec scanalyzer and lemnatec saw bonit. Technical report, LemnaTec.
- [56] Verivide. Website. <http://www.verivide.com/start/en/products/light-cabinets>. Page consultée le 01/11/2015.
- [57] W. Wang and J. Paliwal. Separation and identification of touching kernels and dockage components in digital images. *Canadian biosystems engineering*, 48 :7, 2006.
- [58] J. Weickert and H. Scharr. A scheme for coherence-enhancing diffusion filtering with optimized rotation invariance. *Journal of Visual Communication and Image Representation*, 13(1-2) :103–118, 2002.
- [59] R. J. Woodham. Photometric method for determining surface orientation from multiple images. *Optical engineering*, 19(1) :191139–191139, 1980.
- [60] X-Rite. Website. <http://www.xrite.com/color-measurement-products>. Page consultée le 01/11/2015.
- [61] Q. Yao, Y. Zhou, and J. Wang. An automatic segmentation algorithm for touching rice grains images. In *International Conference on Audio Language and Image Processing (ICALIP)*, pages 802–805, 2010.
- [62] N. Yokoya, M. Kaneta, and K. Yamamoto. Recovery of superquadric primitives from a range image using simulated annealing. In *Proceedings of the International Conference on Pattern Recognition*, pages 168–172, 1992.
- [63] C. T. Zahn and R. Z. Roskies. Fourier descriptors for plane closed curves. *Computers, IEEE Transactions on*, C-21(3) :269–281, March 1972.
- [64] X. Zhang and P.L. Rosin. Superellipse fitting to partial data. *Pattern Recognition*, 36(3) :743–752, 2003.

- [65] Q. Zhong, P. Zhou, Q. Yao, and K. Mao. A novel segmentation algorithm for clustered slender-particles. *Computers and Electronics in Agriculture*, 69(2) :118 – 127, 2009.

Résumé

À l'échelle mondiale, la récolte de céréales atteint plusieurs milliards de tonnes chaque année. Les producteurs céréaliers échangent leurs récoltes selon un prix déterminé par la qualité de leur production. Cette évaluation, appelée agréage, est réalisée pour chaque lot sur un échantillon jugé représentatif. La difficulté au cours de cette évaluation est de parvenir à parfaitement caractériser l'échantillon. Il faut pour cela qualifier chacun de ses éléments, en d'autres termes, il est nécessaire d'évaluer chaque grain de céréale de manière individuelle. Cette opération est historiquement réalisée par un opérateur qui isole chaque grain manuellement pour l'inspecter et l'évaluer. Ce procédé est exposé à différents problèmes : d'une part les résultats obtenus par un opérateur ne sont pas parfaitement répétables : son état de fatigue visuelle peut influencer son appréciation ; d'autre part l'évaluation dépend de l'opérateur : elle n'est pas reproductible, les résultats peuvent varier d'un opérateur à l'autre. Cette thèse a donc pour but de mettre au point un système capable de réaliser cette inspection visuelle. Le système d'acquisition est présenté dans un premier temps. Cette enceinte contient les dispositifs d'éclairage et d'acquisition d'images. Différents outils ont été mis en œuvre pour s'assurer de la justesse et de la stabilité des acquisitions. Une méthode d'apprentissage de modèles de forme est ensuite présentée : elle a pour but de définir et de modéliser le type de forme des grains de l'application considérée (blé, riz, orge). Cette étape est réalisée sur une image d'objets isolés. Deux méthodes de détection sont ensuite présentées : une approche déterministe et une approche probabiliste. Ces deux méthodes, mises au point pour segmenter les objets d'une image, utilisent des outils communs bien qu'elles soient conçues différemment. Les résultats obtenus et présentés dans cette thèse démontrent la capacité du système automatique à se positionner comme une solution fiable à la problématique d'inspection visuelle de grains de céréales.

Abstract

In agriculture, the global grain harvest reached several billion tons each year. Cereal producers exchange their crops at a price determined by the quality of their production. This assessment, called grading, is performed for each set on a representative sample. The difficulty of this assessment is to fully characterize the sample. To do so, it is necessary to qualify each of its elements. In other words, it is necessary to evaluate each individual cereal grain. Historically, this has been performed manually by an operator who isolates each evaluated grain. This method is exposed to various problems : firstly, results obtained by an operator are not perfectly repeatable. For example, eyestrain can influence the assessment. On the other hand the evaluation depends on the operator : it is not reproducible. The results can vary from one operator to another. The aim of this thesis is to develop a system that can handle this visual inspection. In a first time, the acquisition system is introduced. Image acquisition and lighting parts are placed in a cabin. Several methods have been introduced to manage accuracy and stability of the acquisitions. Then, a shape model learning is detailed : this step, based on an image with manually separated objects, defines and modelizes shape of the considered cereal grains (wheat, rice, barley). Two detection approaches are then introduced : a deterministic method and a probabilistic one. Both are based on the same tools to process the objects segmentation of an image, but they deal with the question in a different way. The results provided by the system and presented in this thesis emphasize the ability of this automatic system to process the visual inspection of food products.